

Charakterisierung der Stärke und Richtung von Interaktionen zwischen dynamischen Systemen mit Zellularen Neuronalen Netzen.

Dissertation

zur

Erlangung des Doktorgrades (Dr. rer. nat.)

der

Mathematisch-Naturwissenschaftlichen Fakultät

der

Rheinischen Friedrich-Wilhelms-Universität Bonn

vorgelegt von

Dieter Krug

aus Troisdorf

Bonn, 17. Mai 2010

Angefertigt mit Genehmigung der Mathematisch-Naturwissenschaftlichen
Fakultät der Rheinischen Friedrich-Wilhelms-Universität Bonn

1. Gutachter: Prof. Dr. Klaus Lehnertz
2. Gutachter: Prof. Dr. Ulrike Thoma

Tag der mündlichen Prüfung: 29. Juli 2010

Diese Dissertation ist auf dem Hochschulschriftenserver der ULB Bonn
<http://hss.ulb.uni-bonn.de/diss/online> elektronisch publiziert.

Erschienen 2010

Zusammenfassung

In der vorliegenden Dissertation werden Stärke und Richtung von Interaktionen zwischen komplexen dynamischen Systemen mit Zellularen Neuronalen Netzen (CNN) erfolgreich charakterisiert. Die Berechnung von Kenngrößen zur Charakterisierung von Interaktionen sind im allgemeinen mit einem hohen Rechenaufwand verbunden, so daß Analysen von Felddaten mit herkömmlichen Computern stark limitiert sind. Die attraktiven Eigenschaften der Informationsverarbeitung künstlicher neuronaler Netze sollen daher ausgenutzt werden, um effektiv Interaktionen zwischen dynamischen Systemen zu charakterisieren. Als Grundlage dienen hier nichtlineare Interdependenzmaße als Schätzer für generalisierte Synchronisation, die durch CNN, nach Optimierung der Netzparameter mittels überwachten Lernverfahren, approximiert werden.

Zunächst werden die Grenzen dieser Methode anhand von synthetischen Zeitreihen von Modellsystemen mit deterministisch chaotischer Dynamik überprüft, deren Eigenschaften wohlbekannt sind und durch Kontrollparameter gesteuert werden können. Es wird gezeigt, daß CNN geeignet sind, sowohl die Stärke als auch die Richtung von Interaktionen zwischen strukturell identischen und strukturell unterschiedlichen Systemen zu schätzen. Dies ermöglicht einerseits die Unterscheidung der verschiedenen Regimes unabhängiger, intermittenter und synchronisierter Systeme sowie andererseits die korrekte Detektion der Interaktionsrichtung auch im Falle schwach interagierender Systeme.

Zur Überprüfung der Eignung von CNN zur Charakterisierung von Interaktionen zwischen komplexen natürlichen dynamischen Systemen werden lang andauernde Vielkanalaufzeichnungen hirnelektrischer Aktivität von Patienten mit fokaler Epilepsie untersucht. Es wird gezeigt, daß sowohl die Stärke als auch die Richtung von Interaktionen zwischen verschiedenen Hirnstrukturen selbst bei lokal unterschiedlichen Dynamiken zuverlässig mit CNN geschätzt werden können. Darüber hinaus werden die Generalisierungseigenschaften der CNN untersucht. Hier wird gezeigt, daß die Schätzung der Interaktionsstärke bzw. Interaktionsrichtung zwischen verschiedenen Hirnstrukturen ohne spezifische Nachoptimierung möglich ist. In vielen Fällen ist sogar die Schätzung von Stärke und Richtung der Interaktionen ohne individuelle Nachoptimierung für verschiedene Patienten möglich. Abschließend wird die Eignung der CNN-basierten Approximationen von Interaktionseigenschaften für die Detektion von Merkmalen untersucht, die auf einen bevorstehenden epileptischen Anfall hindeuten. Es wird gezeigt, daß die Variationen der nichtlinearen Interdependenzmaße für Stärke und Richtung bezüglich eines angenommenen Voranfallszustandes mit CNN reproduziert werden können.

Inhaltsverzeichnis

1	Einleitung	5
2	Synchronisation	9
2.1	Dynamische Systeme	9
2.2	Kopplung dynamischer Systeme	10
2.3	Zustandsraumrekonstruktion	12
2.4	Synchronisationsarten	13
2.4.1	Identische Synchronisation	13
2.4.2	Zeitversatzsynchronisation	14
2.4.3	Phasensynchronisation	14
2.4.4	Generalisierte Synchronisation	15
2.5	Nichtlineare Interdependenz	16
2.5.1	Interdependenzmaß S	16
2.5.2	Interdependenzmaß H	18
2.5.3	Interdependenzmaß N	19
2.5.4	Theiler-Korrektur	19
2.5.5	Asymmetrie	19
2.6	Synchronisationsregime	21
3	Künstliche neuronale Netze	23
3.1	Biologische neuronale Netze	23
3.2	Motivation für künstliche neuronale Netze	24
3.3	Entwicklung künstlicher neuronaler Netze	25
3.4	Zellulare Neuronale Netze (CNN)	28
3.4.1	Isolierte Zelle	31
3.4.2	Aktivierungsfunktion	31
3.4.3	Einflussumgebung	32
3.4.4	Randbedingungen	33
3.4.5	Zustandsgleichung und Kopplungsgewichte	33
3.5	In-Sample Optimierung der Kopplungsgewichte	35
3.5.1	Minimierungsproblem	36
3.5.2	Überanpassung, Testmenge	37
3.5.3	Out-Of-Sample Validierung	39

4	Charakterisierung von Synchronisationsphänomenen mit CNN	41
4.1	Datenvorverarbeitung	42
4.2	Software-CNN	46
4.3	Optimierung	46
4.3.1	Evolutionäres Minimierungsverfahren	48
4.4	Validierung	50
5	Analyse von synthetischen Zeitreihen	53
5.1	Strukturell ähnliche Systeme	54
5.1.1	Symmetrisches Interdependenzmaß	54
5.1.2	Asymmetrisches Interdependenzmaß	56
5.2	Strukturell unterschiedliche Systeme	58
5.2.1	Symmetrisches Interdependenzmaß	58
5.2.2	Asymmetrisches Interdependenzmaß	59
5.3	Diskussion	61
6	Analyse von Zeitreihen hirnelektrischer Aktivität	63
6.1	Epilepsie, Elektroenzephalogramm	63
6.2	Analyse des Elektroenzephalogramms	65
6.3	Datengrundlage	66
6.4	Zusammenstellung der Trainings- und Testmengen	68
6.5	Validierung	69
6.6	Auswahl von CNN nach einem Optimierungsverfahren	70
6.7	Charakterisierung der Stärke von Interaktionen	73
6.7.1	Optimierung und Validierung mit Zeitreihen einzelner Elektrodenkombinationen individueller Patienten	74
6.7.2	Generalisierungseigenschaften	82
6.7.3	Prädiktive Merkmale	93
6.7.4	Diskussion	98
6.8	Charakterisierung der Richtung von Interaktionen	98
6.8.1	Optimierung und Validierung mit Zeitreihen einzelner Elektrodenkombinationen individueller Patienten	99
6.8.2	Generalisierungseigenschaften	105
6.8.3	Prädiktive Merkmale	115
6.8.4	Diskussion	117
7	Zusammenfassung und Ausblick	119
A	Modellsysteme	123
A.1	Rössleroszillator	123
A.2	Lorenzoszillator	124
A.3	Bidirektional gekoppelte Rössleroszillatoren	125

A.4	Unidirektional gekoppelte Rössleroszillatoren	125
A.5	Unidirektional gekoppelte Rössler- und Lorenzoszillatoren	126
B	Verzeichnis der CNN-Templates	127
	Literatur	141
	Eigene Veröffentlichungen	159

1 Einleitung

Die erste Erwähnung eines Synchronisationsphänomens geht auf den niederländischen Astronom, Mathematiker und Physiker Christiaan Huygens zurück. Er beobachtete im 17. Jahrhundert, daß zwei Pendeluhr, welche an einem gemeinsamen Balken aufgehängt waren, nach einem Einschwingvorgang stets eine gegenphasige Oszillation aufwiesen [Huy73]. Bis heute wurden Synchronisationsphänomene in vielen Bereichen der Physik nachgewiesen. Beispielhaft seien hier aktuellere Studien im Bereich der Mechanik [UMP09], der Laserphysik [DBOR01, AAGM01, DBOR04, AP09] oder der Signalübertragung [AMPR04, AHM⁺05, PM08, MG09] genannt. In jüngerer Zeit verlagerte sich der Schwerpunkt der Forschung auch in andere Naturwissenschaften wie der Chemie (beispielsweise interagierende chemische Oszillatoren auf Basis einer Belousov-Zhabotinsky-Reaktion [FNK03]) oder Biologie (beispielsweise Synchronisation zwischen Jäger-Beute Populationen [BJHH09]). Auch für den Menschen spielen Synchronisationsphänomene eine große Rolle. So treten zirkadiane Schwankungen der Körpertemperatur, des Blutdrucks oder der Hormonproduktion auf, die hauptsächlich durch das Tageslicht gesteuert werden [HdW09]. Darüber hinaus haben Synchronisationseffekte auch Einfluss auf den Herzschlag. Hier konnte beispielsweise ein Zusammenhang zwischen Herzschlag und Atmung [SRKA98] oder eine Adaption des Herzschlages zwischen Fötus und Mutter [LGT⁺09] nachgewiesen werden. Eine große Rolle spielen Synchronisationsphänomene ebenfalls in den Neurowissenschaften. Einerseits stellt die Synchronisation von Neuronenverbänden eine Voraussetzung für die normale Funktionalität des Gehirns dar, während andererseits eine abnorme neuronale Synchronisation in Zusammenhang mit verschiedenen Erkrankungen wie Schizophrenie, Morbus Parkinson, Autismus, Morbus Alzheimer und Epilepsie gebracht wird [VLRM01, Gla01, SG05, US06, Buz06].

Ausgehend von der Beschreibung von Synchronisation als „Anpassung von Rhythmen aufgrund einer schwachen Interaktion“ [PRK01] wurden im Laufe der Zeit diverse mathematische Konzepte entwickelt, um die verschiedenen beobachtbaren Synchronisationsphänomene zu beschreiben. *Identische Synchronisation* bzw. *Zeitversatzsynchronisation* liegt vor, wenn sich Systemzustände identisch bzw. bis auf einen Zeitversatz identisch entwickeln [RPK97]. Da diese Konzepte für die Charakterisierung von Synchronisationsphänomenen aus Felddaten beispielsweise auf-

grund von Meßrauschen unpraktikabel sind, wurden weitere Ansätze entwickelt, die subtilere Abhängigkeiten zwischen dynamischen Systemen erfassen. Einer davon ist die *Phasensynchronisation*, die auf einer Beschränktheit der Phasendifferenzen basiert. Hierbei ist entscheidend, daß eine Phase sinnvoll definiert werden kann. In diesem Zusammenhang spielt die Tatsache, daß auch nicht streng periodische Oszillatoren Synchronisation aufweisen, eine entscheidende Rolle. So konnte nachgewiesen werden, daß sogar gekoppelte chaotische Systeme, deren zeitliche Entwicklungen sensitiv von den Anfangsbedingungen abhängen, Phasensynchronisation aufweisen [PCJ⁺97, PRK01]. Dies war mit einer der Gründe für die Entwicklung des Konzeptes der *Generalisierten Synchronisation*, welches lediglich die Existenz eines funktionellen Zusammenhanges der Zustände der beteiligten Systeme fordert. Versuche, eine vereinheitlichende Theorie zur Beschreibung aller Synchronisationsphänomene zu entwickeln, werden in der Literatur kontrovers diskutiert [BK00, BPP01, HK05].

Ausgehend von den genannten Konzepten wurde im Rahmen der Theorie nichtlinearer dynamischer Systeme und der Synchronisationstheorie eine Reihe von *Synchronisationsmaßen* entwickelt, die es ermöglichen, Interaktionen zwischen dynamischen Systemen zu messen [BKO⁺02]. Dabei läßt sich zwischen Maßen unterscheiden, die die Stärke einer Interaktion erfassen sowie Maßen, die die Richtung einer Interaktion detektieren. Zur Charakterisierung der generalisierten Synchronisation wurden *nichtlineare Interdependenzmaße* entwickelt [AGLE99, QAG00, QKKG02, CA09]. Da diese auf geometrischen Beziehungen in den, aus Observablen rekonstruierten, Zustandsräumen basieren, werden sämtliche Eigenschaften der Systemdynamiken wie Phasen- oder Amplitudeninformationen berücksichtigt. Darüber hinaus bieten nichtlineare Interdependenzmaße die Möglichkeit, sowohl Stärke als auch Richtung von Interaktionen abzuschätzen.

Die Berechnung von Synchronisationsmaßen ist aufgrund komplexer Algorithmen im Allgemeinen mit einem hohen Rechenaufwand verbunden. Hinzu kommt, daß die benötigte Rechenkapazität quadratisch mit der Anzahl der zu untersuchenden Systeme ansteigt. Dies schränkt die Analyse von Felddaten mit Computern der von Neumann-Architektur stark ein. Eine Alternative zur Berechnung von Synchronisationsmaßen oder auch anderen charakteristischen Kenngrößen könnten *künstliche neuronale Netze* bieten. Inspiriert durch biologische neuronale Netze wie das menschliche Gehirn bestehen diese aus untereinander vernetzten, relativ einfachen Verarbeitungseinheiten, die Zellen genannt werden, um eine Abgrenzung zu den biologischen Neuronen herzustellen. Künstliche neuronale Netze bieten eine stark parallelisierte und somit schnelle Verarbeitung von Informationen. Darüber hinaus besitzen sie die Fähigkeit, Aufgaben anhand von Beispielen zu erlernen und müssen somit nicht programmiert werden [WRB93]. Künstliche neuronale Netze wurden dabei in vielen Studien bereits erfolgreich für verschiedene Aspekte

der Zeitreihenanalyse eingesetzt [APHF92, PRK92, EKKK95, KPP97, BSG⁺00, FKK02, ST02, CK04, CGC⁺05, PTPV06, GRG06]. Allerdings sind künstliche neuronale Netze aufgrund komplexer Vernetzungstopologien mit aktuellen Fertigungstechniken nicht oder nur sehr aufwändig als Hardware realisierbar und nur schwierig am Computer effektiv zu simulieren. Daher schlugen Chua und Yang das Konzept der Zellularen Neuronalen Netze (CNN) vor [CY88b, CY88a]. Durch lediglich lokale Kopplungen und die Anordnung der Zellen auf einem regulären Gitter konnten bereits miniaturisierte und energieeffiziente analoge VLSI-Implementationen von CNN realisiert werden [RRV00, RR02, RLC⁺04, LPKH02, LPKH04]. Auch CNN konnten in den letzten Jahren erfolgreich in der Zeitreihenanalyse eingesetzt werden. So konnten univariate Eigenschaften von Systemen wie eine effektive Korrelationsdimension [TKAW99], Stabilitätseigenschaften [Kra06] oder Komplexitätsänderungen [Wan07] von dynamischen Systemen mit CNN geschätzt werden. Darüber hinaus konnte ebenfalls gezeigt werden, daß es mit CNN möglich ist, ein phasenbasiertes Synchronisationsmaß zu schätzen [Sow04, SCML05].

Ziel der vorliegenden Dissertation war die Charakterisierung generalisierter Synchronisation in interagierenden dynamischen Systemen hinsichtlich Stärke und Richtung von Interaktionen mittels nichtlinearer Interdependenzmaße. Die Maße wurden dabei mit CNN approximiert, indem die Netzparameter jeweils durch ein iteratives Optimierungsverfahren anhand von Beispieldaten bestimmt wurden. Durch die hohe Verarbeitungsgeschwindigkeit von CNN oder der Möglichkeit, energie- und raumsparende Hardwareimplementationen zu realisieren, kann eine effektivere Charakterisierung von Interaktionen dynamischer Systeme erreicht werden, als es mit Rechnern der von Neumann-Architektur möglich ist.

In den Kapiteln 2 und 3 werden zunächst die theoretischen Grundlagen dynamischer Systeme und der Synchronisationskonzepte sowie künstlicher neuronaler Netze vorgestellt. In Kapitel 4 wird die Vorgehensweise erläutert, wie CNN durch ein iteratives Optimierungsverfahren nichtlineare Interdependenzmaße *erlernen* können. Um die Grenzen dieses Ansatzes unter kontrollierten Bedingungen zu überprüfen, werden zunächst interagierende Modellsysteme untersucht, deren Eigenschaften wohlbekannt sind und durch Kontrollparameter gesteuert werden können (Kapitel 5). Als Beispiel für eine Analyse von Felddaten werden Zeitreihen hirnelektrischer Aktivität von Epilepsiepatienten untersucht (Kapitel 6). Zum einen wurde überprüft, ob eine Schätzung der Interaktionsstärke bzw. -richtung zwischen Hirnstrukturen mit CNN möglich ist. Zum anderen wurden die Generalisierungseigenschaften von CNN untersucht. Hierbei stand die Fragestellung im Vordergrund, ob CNN, welche Interaktionen zwischen bestimmten dynamischen Systemen erlernt haben, auch eine Charakterisierung der Interaktionen ähnlicher Systeme ohne weitere Optimierung erlauben. Die Dissertation schließt mit einer Zusammenfassung und einem Ausblick in Kapitel 7.

2 Synchronisation

In diesem Kapitel werden die mathematischen Grundlagen für die in dieser Arbeit verwendeten Synchronisationsmaße erläutert (siehe auch [KS03]). Dabei erfolgt zunächst eine Betrachtung dynamischer Systeme. Anschließend werden verschiedene in der Literatur (für eine Übersicht siehe [PRK01]) etablierte Ansätze vorgestellt, mit denen Synchronisationsphänomene zwischen zwei Zeitreihen dynamischer Systeme untersucht werden können. Daran anschließend werden die in dieser Arbeit verwendeten Konzepte der generalisierten Synchronisation und der nichtlinearen Interdependenz vorgestellt.

2.1 Dynamische Systeme

Wird der Zustand eines dynamischen Systems durch einen Satz von d Variablen $\kappa_n(t)$ mit $n = 1, \dots, d$ zu jedem Zeitpunkt t vollständig beschrieben, so ist eine geometrische Repräsentation des Systems in einem d -dimensionalen Zustandsraum möglich:

$$\vec{\kappa}(t) = (\kappa_1(t), \dots, \kappa_d(t)) \quad \vec{\kappa}(t) \in \mathbb{R}^d. \quad (2.1)$$

Dabei handelt es sich um ein *deterministisches* System, wenn eine - i.a. nichtlineare - Funktion $F_{(d)}^{\vec{}}$ existiert, welche zu allen möglichen Zuständen des Systems die zukünftige Entwicklung eindeutig beschreibt:

$$\dot{\vec{\kappa}}(t) = F_{(d)}^{\vec{}}(\vec{\kappa}(t), t) \quad F_{(d)}^{\vec{}} : \mathbb{R}^d \rightarrow \mathbb{R}^d. \quad (2.2)$$

Durch die zeitliche Entwicklung der Systemzustände gemäß dieser Funktion wird im Zustandsraum die Bahn des Zustandsvektors $\vec{\kappa}(t)$ - die *Trajektorie* des Systems - beschrieben. Aufgrund der Eindeutigkeit der zeitlichen Entwicklung können sich

Trajektorien im Zustandsraum nicht kreuzen. Ist $F_{(d)}^{\vec{}}$ nicht explizit zeitabhängig, handelt es sich um eine *stationäre* Dynamik:

$$\dot{\vec{\kappa}}(t) = F_{(d)}^{\vec{}}(\vec{\kappa}(t)) \quad F_{(d)}^{\vec{}} : \mathbb{R}^d \rightarrow \mathbb{R}^d. \quad (2.3)$$

Für dissipative Systeme existiert eine Untermenge A des Zustandsraums, welche *Attraktor* genannt wird. Sämtliche Trajektorien, welche durch ihre Startbedingungen im *Attraktionsbecken* dieses Attraktors starten, nähern sich diesem asymptotisch an. Der Satz von Liouville sagt nun aus, daß die Entwicklung der Größe des Zustandsraumvolumens $V_p(t)$ von der Divergenz des Flussfeldes G_f abhängt:

$$V_p(t) = V_p(0)e^{\text{div } G_f(t)}. \quad (2.4)$$

Hieran wird deutlich, daß nur Systeme für die $\text{div } G_f(t) < 0$ gilt - also dissipative Systeme - einen Attraktor besitzen können. Die Trajektorien konservativer bzw. hamiltonscher Systeme, für die $\text{div } G_f(t) = 0$ gilt, erhalten das Zustandsraumvolumen und können so nicht auf einen Attraktor zulaufen. Die einfachsten Attraktoren sind Fixpunkte (beispielsweise für ein Pendel mit Reibung) oder periodische Orbits (auch limit cycle genannt; beispielsweise bei einem getriebenen Pendel).

Die in dieser Arbeit verwendeten Modellsysteme (siehe Anhang A) weisen ein deterministisch *chaotisches* Verhalten auf. Dieses ist charakterisiert durch eine exponentielle Divergenz von zwei initial beliebig nah benachbarten Trajektoriensegmenten im Zustandsraum. Die Attraktoren bilden dabei keine geschlossene Kurve und weisen eine fraktale, d.h. ungeradzahlige, Dimension¹ auf, weshalb sie *seltsam* genannt werden.

2.2 Kopplung dynamischer Systeme

Gegeben seien zwei unabhängige dynamische Systeme X und Y mit den Bewegungsgleichungen:

¹Beispielsweise die Box-counting Dimension [KS03].

$$\begin{aligned}\dot{\vec{\kappa}}(t) &= F_{(d)_\kappa}^{\vec{}}(\vec{\kappa}(t)) \quad \vec{\kappa} \in \mathbb{R}^{d_\kappa} \quad F_{(d)_\kappa}^{\vec{}} : \mathbb{R}^{d_\kappa} \rightarrow \mathbb{R}^{d_\kappa} \\ \dot{\vec{\lambda}}(t) &= F_{(d)_\lambda}^{\vec{}}(\vec{\lambda}(t)) \quad \vec{\lambda} \in \mathbb{R}^{d_\lambda} \quad F_{(d)_\lambda}^{\vec{}} : \mathbb{R}^{d_\lambda} \rightarrow \mathbb{R}^{d_\lambda}.\end{aligned}\tag{2.5}$$

Besteht zwischen den Systemen eine Kopplung, so kann die zeitliche Entwicklung der jeweiligen Zustände durch modifizierte Bewegungsgleichungen repräsentiert werden:

$$\begin{aligned}\dot{\vec{\kappa}}(t) &= F_{(d)_\kappa}^{\vec{*}}(\vec{\kappa}(t), \vec{\lambda}(t)) \quad \vec{\kappa} \in \mathbb{R}^{d_\kappa} \quad F_{(d)_\kappa}^{\vec{*}} : \mathbb{R}^{d_\kappa+d_\lambda} \rightarrow \mathbb{R}^{d_\kappa} \\ \dot{\vec{\lambda}}(t) &= F_{(d)_\lambda}^{\vec{*}}(\vec{\lambda}(t), \vec{\kappa}(t)) \quad \vec{\lambda} \in \mathbb{R}^{d_\lambda} \quad F_{(d)_\lambda}^{\vec{*}} : \mathbb{R}^{d_\kappa+d_\lambda} \rightarrow \mathbb{R}^{d_\lambda}.\end{aligned}\tag{2.6}$$

Aus den Gleichungen ist ersichtlich, daß die Trajektorien von X und Y jeweils eine durch $F_{(d)_\kappa}^{\vec{*}}$ und $F_{(d)_\lambda}^{\vec{*}}$ definierte Projektion des gemeinsamen Zustandsraumes sind. Hierbei gilt meist, daß die Dimensionalität des Gesamtsystems kleiner ist als die Summe der Dimensionen der Einzelsysteme:

$$d_{\kappa \oplus \lambda} \leq d_\kappa + d_\lambda.\tag{2.7}$$

Die in der vorliegenden Arbeit genutzten Modellsysteme (siehe Anhang A) werden ausschließlich über den Kopplungsparameter ϵ diffusiv [AEK90] gekoppelt:

$$\begin{aligned}F_{(d)_\kappa}^{\vec{*}}(\vec{\kappa}(t), \vec{\lambda}(t)) &= F_{(d)_\kappa}^{\vec{}}(\vec{\kappa}(t)) + \epsilon_\kappa K_{m\kappa}(\vec{\lambda}(t) - \vec{\kappa}(t)) \\ F_{(d)_\lambda}^{\vec{*}}(\vec{\lambda}(t), \vec{\kappa}(t)) &= F_{(d)_\lambda}^{\vec{}}(\vec{\lambda}(t)) + \epsilon_\lambda K_{m\lambda}(\vec{\kappa}(t) - \vec{\lambda}(t)).\end{aligned}\tag{2.8}$$

$K_{m\kappa}$ und $K_{m\lambda}$ sind hierbei $d_\kappa \times d_\lambda$ bzw. $d_\lambda \times d_\kappa$ Matrizen, über die gesteuert wird, welche Komponenten des einen Systems in welche Komponenten des anderen eingekoppelt werden. Falls entweder $\epsilon_\kappa = 0$ oder $\epsilon_\lambda = 0$ wird die Kopplung unidirektional (oder driver-responder-Kopplung) genannt, für $\epsilon_\kappa, \epsilon_\lambda > 0$ bidirektional.

2.3 Zustandsraumrekonstruktion

Bei Untersuchungen realer Systeme sind im Allgemeinen weder die Bewegungsgleichungen noch die Anzahl der Freiheitsgrade oder gar die Zustandsvektoren bekannt. Vielmehr wird eine Messung einer skalaren Systemobservablen x , in diskreten - meist äquidistanten - Zeitschritten Δt durchgeführt, wodurch eine *Zeitreihe* erhalten werden kann²:

$$(x_i) = \psi(\vec{\kappa}_i) \quad i = 1, \dots, M_z. \quad (2.9)$$

Die x_i folgen dabei gemäß einer Meßfunktion ψ aus den Systemzuständen $\vec{\kappa}_i$.

Der Übersichtlichkeit halber wurde die explizite Angabe der Zeit durch den Index i wie folgt ersetzt:

$$\kappa_i = \kappa(i\Delta t), \quad i = 0, \dots, M_z - 1 \quad (2.10)$$

$$x_i = x(i\Delta t), \quad i = 0, \dots, M_z - 1. \quad (2.11)$$

Nach Takens ist es möglich - für rauschfreie Daten - aus den x_i einen Zustandsraum zu rekonstruieren, der topologisch äquivalent zum tatsächlichen Zustandsraum des Systems ist [Tak81]. Hierzu wird eine Zeitverzögerungseinbettung der Meßwerte x_i mit einem Delay τ in Zustandsraumvektoren der Einbettungsdimension m durchgeführt:

$$\vec{x}_i = (x_i, x_{i-\tau}, \dots, x_{i-(m-1)\tau}) \quad i = 1, \dots, M_z - (m-1)\tau. \quad (2.12)$$

Die Wahl der Parameter τ und m hat entscheidenden Einfluss auf den rekonstruierten Zustandsraum. So ist gemäß Sauer et al. [SYC91] ein topologisch äquivalenter Zustandsraum nur für $m > 2d$ gewährleistet, wenn d die tatsächliche Dimensionalität des Systems ist³. Wird eine zu kleine Einbettungsdimension gewählt, kann es

²Mathematisch unexakt hat sich der Begriff Zeitreihe durchgesetzt obwohl es sich streng genommen um eine Folge handelt.

³Ursprünglich stellte Whitney die Bedingung $m \geq 2d + 1$ auf [Whi36], welche für ganzzahlige d der Bedingung von Sauer et al. entspricht. In der Praxis genügen häufig jedoch auch kleinere Einbettungsdimensionen.

zu Überschneidungen der rekonstruierten Trajektorie kommen, was den oben genannten Prinzipien eines deterministischen Systems widerspricht und folglich keine topologische Äquivalenz bieten kann ([Cas91, GFC⁺92, KS03]). Umgekehrt ist der Einbettungsdimension keine obere Schranke gesetzt, bei der die topologische Äquivalenz nicht mehr gewährleistet wäre. Jedoch zeigt sich bei der Analyse von Felddaten, daß insbesondere bei der Untersuchung von chaotischen Systemen Probleme auftreten können. Da bei einer hohen Einbettungsdimension die ersten und letzten Einträge der Zustandsraumvektoren \vec{x} zeitlich weit auseinanderliegen und somit durch den chaotischen Charakter des Systems wenig korreliert sind, können verschiedene Analyseverfahren die Dynamik des Systems nur schwer erfassen.

Die Zeitverzögerung τ ist bei diskreten Zeitreihen für gewöhnlich ein Vielfaches des Abtastintervalls Δt , um nicht auf Interpolationen zwischen den Meßpunkten zurückgreifen zu müssen. Dabei muß τ auf die Zeitskalen des betrachteten Systems abgestimmt sein. Wird τ zu klein gewählt, sind die Einträge der rekonstruierten Vektoren nahezu identisch und diese befinden sich weitgehend in einem Schlauch um die Diagonale des Zustandsraumes. Das andere Extrem einer zu großen Verzögerung führt insbesondere bei chaotischen Systemen dazu, daß die Einträge der rekonstruierten Vektoren kaum korreliert sind und somit eine Wolke im Zustandsraum bilden. An dieser Stelle sei noch erwähnt, daß τ die topologische Äquivalenz im mathematischen Sinne nicht beeinflusst, es jedoch in der Praxis für die Berechnung verschiedener Kenngrößen nützlich ist, eine optimal entfaltete Trajektorie zu rekonstruieren. Ein übliches Maß, um ein günstiges τ abzuschätzen, ist die Dekorrelationszeit der Zeitreihe [KS03].

2.4 Synchronisationsarten

Aufgrund der Existenz verschiedener Synchronisationsphänomene zwischen dynamischen Systemen etablierten sich in der Literatur unterschiedliche mathematische Konzepte zu ihrer Beschreibung, welche im folgenden vorgestellt werden. Darüber hinaus gibt es Bestrebungen, diese Ansätze in eine einheitliche Theorie zusammenzuführen, welche aber zur Zeit noch diskutiert werden [BK00, BPP01, HK05].

2.4.1 Identische Synchronisation

Zwei dynamische Systeme X und Y synchronisieren genau dann identisch, wenn sich ihre Zustandsvektoren $\vec{x}(t)$ und $\vec{y}(t)$ asymptotisch einander annähern:

$$\lim_{t \rightarrow \infty} |\vec{x}(t) - \vec{y}(t)| = 0. \quad (2.13)$$

Diese Art der Synchronisation kann lediglich bei identischen Systemen oder bei unendlich großer Kopplung auftreten [RPK97].

2.4.2 Zeitversatzsynchronisation

Die Zeitversatzsynchronisation [RPK97] stellt eine Verallgemeinerung der identischen Synchronisation insofern dar, als daß zwischen den Zuständen der beiden Systeme ein Zeitversatz ΔT erlaubt wird:

$$\lim_{t \rightarrow \infty} |\vec{x}(t + \Delta T) - \vec{y}(t)| = 0. \quad (2.14)$$

Offenbar entspricht für $\Delta T = 0$ die Zeitversatzsynchronisation der identischen Synchronisation.

Diese beiden Konzepte sind zunächst sehr intuitiv, bergen aber für praktische Zwecke viele Probleme, da beispielsweise die Bedingungen für verdrauschte Meßreihen nicht exakt erfüllt werden können.

2.4.3 Phasensynchronisation

Die Anpassung von Rhythmen zweier Oszillatoren kann mathematisch mit dem Konzept der *Phasensynchronisation* beschrieben werden. Seien $\phi^X(t)$ und $\phi^Y(t)$ die Phasen zweier Systeme X und Y , so sind diese phasensynchronisiert, wenn gilt:

$$\alpha\phi^X(t) - \beta\phi^Y(t) = \text{const.}, \quad \alpha, \beta \in \mathbb{N}. \quad (2.15)$$

Phasensynchronisation kann jedoch ebenfalls für nicht periodische oder gar chaotische Systeme definiert werden, wofür zunächst eine Verallgemeinerung des Phasenbegriffes notwendig ist. Phasen solcher Systeme können beispielsweise mit Hilbert- oder Wavelettransformationen aus Zeitreihen extrahiert werden. Ebenso muß die

oben genannte Bedingung (Gleichung 2.15) abgeändert werden, da durch die Instabilität der Trajektorien chaotischer Systeme keine konstante Phasendifferenz über einen längeren Zeitraum erwartet werden kann:

$$\alpha\phi^X(t) - \beta\phi^Y(t) < \text{const.}, \quad \alpha, \beta \in \mathbb{N}. \quad (2.16)$$

Die Phasendifferenz wird also lediglich als beschränkt gefordert. Das noch schwächere Kriterium der *mittleren Phasensynchronisation* wurde in [PRK01] definiert:

$$\alpha \left\langle \frac{d\phi^X}{dt} \right\rangle = \beta \left\langle \frac{d\phi^Y}{dt} \right\rangle, \quad \alpha, \beta \in \mathbb{N}. \quad (2.17)$$

Die Forderung nach einem rationalen Verhältnis der mittleren Frequenzen ist jedoch bei sehr ähnlichen Systemen mit ähnlichen Eigenfrequenzen problematisch, da hier eine Synchronisation unter Umständen fälschlicherweise auch im ungekoppelten Fall detektiert würde.

2.4.4 Generalisierte Synchronisation

Das Konzept der *generalisierten Synchronisation* soll eine möglichst allgemeine Definition von Synchronisation bereitstellen. Ursprünglich wurde das Phänomen synchronisierender chaotischer dynamischer Systeme beobachtet [FY83, AVR86, PC90, CP93] und Synchronisation zwischen diesen als Gleichheit der jeweiligen Observablen gedeutet. Die Beobachtung, daß sich chaotische Systeme auch gegenseitig beeinflussen können, ohne daß sich ihre Observablen identisch entwickeln, führte zu einer Generalisierung dieser starren Bedingung [RSTA95, ARS96]. Es etablierte sich daher die Forderung nach einem funktionellen Zusammenhang zwischen den beobachteten Systemen und damit der Begriff der generalisierten Synchronisation:

$$\vec{y}(t) = \vec{\mathcal{F}}(\vec{x}(t)). \quad (2.18)$$

In den frühen Arbeiten [FY83, AVR86, PC90, CP93] spielten Eigenschaften von $\vec{\mathcal{F}}$ wie Stetigkeit oder Differenzierbarkeit zunächst eine untergeordnete Rolle. Es wurden jedoch Methoden entwickelt, die es möglich machen, die mathematischen

Eigenschaften des Funktional $\vec{\mathcal{F}}$ ohne dessen exakte Kenntnis anhand gemessener Zeitreihen zu charakterisieren [PCH95, SSC⁺96].

Der Fall der identischen Synchronisation ist zum Beispiel trivialerweise enthalten wenn $\vec{\mathcal{F}}$ die Identität ist. In Zeitreihen, die an realen Systemen gemessen wurden, ist $\vec{\mathcal{F}}$ jedoch unbekannt und lediglich unter bestimmten Bedingungen rekonstruierbar. Daher wurden mehrere Ansätze vorgestellt, mit denen aus den Trajektorien in den Zustandsräumen dynamischer Systeme die Existenz eines solchen funktionellen Zusammenhangs nachgewiesen werden kann. Dabei wird u.a. ausgenutzt, daß die zukünftige Entwicklung von Zuständen des einen Systems unter Hinzunahme von Zustandsvektoren des anderen Systems mit kleineren Fehlern vorhergesagt werden kann, wenn Gleichung 2.18 gilt [RSTA95, SSC⁺96].

Diese Ansätze stellen jedoch hohe Ansprüche an die Qualität der Daten und der Zustandsraumrekonstruktion. Arnhold et al. [AGLE99] stellten daher Maße für *nicht-lineare Interdependenz* vor, die mit wenigen Annahmen zu robusten Ergebnissen führen. Hierbei wird die Existenz eines funktionellen Zusammenhanges 2.18 nicht gefordert.

2.5 Nichtlineare Interdependenz

Gegeben seien in allen folgenden Fällen zwei Systeme X und Y und die zugehörigen Zeitreihen geeigneter Observablen $(x_1, x_2, \dots, x_{M_z})$ sowie $(y_1, y_2, \dots, y_{M_z})$. Durch eine Zeitverzögerungseinbettung (siehe Gleichung 2.12) werden die Zustandsvektoren $\vec{x}_n = (x_n, x_{n-1}, \dots, x_{n-(m-1)\tau})$ sowie $\vec{y}_n = (y_n, y_{n-1}, \dots, y_{n-(m-1)\tau})$ rekonstruiert. Zusätzlich sei $M_r = M_z - (m - 1)$ die Anzahl der rekonstruierten Vektoren.

2.5.1 Interdependenzmaß S

Seien $r_{n,j}$ und $s_{n,j}$, $j = 1, \dots, k$ die Zeitindizes der k räumlich nächsten Nachbarn von \vec{x}_n bzw. \vec{y}_n . Dann ist der mittlere quadratische euklidische Abstand eines Vektors \vec{x}_n zu seinen k nächsten Nachbarn im Zustandsraum definiert als

$$R_n^{(k)}(X) = \frac{1}{k} \sum_{j=1}^k (\vec{x}_n - \vec{x}_{r_{n,j}})^2. \quad (2.19)$$

Der *konditionierte* mittlere quadratische euklidische Abstand ergibt sich nun durch Ersetzung der Zeitindizes $r_{n,j}$ durch die Zeitindizes $s_{n,j}$ der nächsten Nachbarn von \vec{y}_n aus System Y :

$$R_n^{(k)}(X|Y) = \frac{1}{k} \sum_{j=1}^k (\vec{x}_n - \vec{x}_{s_{n,j}})^2. \quad (2.20)$$

Analog können diese Größen für Zustandsvektoren aus System Y definiert werden:

$$R_n^{(k)}(Y) = \frac{1}{k} \sum_{j=1}^k (\vec{y}_n - \vec{y}_{s_{n,j}})^2 \quad (2.21)$$

und

$$R_n^{(k)}(Y|X) = \frac{1}{k} \sum_{j=1}^k (\vec{y}_n - \vec{y}_{r_{n,j}})^2. \quad (2.22)$$

Mit diesen Größen wird das Interdependenzmaß $S^{(k)}$ gemäß [AGLE99] definiert als:

$$S^{(k)}(X|Y) = \frac{1}{M_r} \sum_{n=1}^{M_r} \frac{R_n^{(k)}(X)}{R_n^{(k)}(X|Y)}. \quad (2.23)$$

Für den Fall identischer Systeme gilt offensichtlich $R_n^{(k)}(X) = R_n^{(k)}(X|Y)$ womit $S^{(k)}(X|Y) = 1$. Für unabhängige Systeme gilt $R_n^{(k)}(X) \leq R_n^{(k)}(X|Y)$, so daß $S^{(k)}(X|Y)$ gegen null tendiert und somit $0 < S^{(k)}(X|Y) \leq 1$ gilt. Hier kann eine Abschätzung vorgenommen werden, welchen Wert $S^{(k)}(X|Y)$ bei unabhängigen Systemen annehmen wird, abhängig von der Anzahl nächster Nachbarn k , der Anzahl der Vektoren des Zustandsraums M_r sowie der effektiven Dimension d_e der rekonstruierten Dynamiken [AGLE99]:

$$S^{(k)}(X|Y) = \left(\frac{k}{M_r} \right)^{\frac{2}{d_e}} \ll 1 \quad (2.24)$$

Die Größe der lokalen Nachbarschaft und des Attraktors wird hierbei mit Hilfe von k und M_r abgeschätzt, wobei eine Normierung entsprechend der Einbettungsdimension m erfolgen muß⁴. Gilt $S^{(k)}(X|Y) \gg \left(\frac{k}{M_r}\right)^{\frac{2}{d_e}}$, besteht Interdependenz zwischen den Systemen X und Y .

2.5.2 Interdependenzmaß H

Das Interdependenzmaß $S^{(k)}$ beruht auf dem Vergleich der lokalen Nachbarschaft eines Zustandsraumvektors $R_n^{(k)}(X)$ mit der durch das andere System konditionierten lokalen Nachbarschaft $R_n^{(k)}(X|Y)$. Mit dem Interdependenzmaß $H^{(k)}$ wird ein anderer Ansatz verfolgt, indem ein für die Zustandsraumvektoren \vec{x}_n globaler mittlerer Abstand zu zufälligen Punkten der Trajektorie definiert wird⁵:

$$R_n(X) = \frac{1}{M_r - 1} \sum_{j \neq n} (\vec{x}_n - \vec{x}_j)^2. \quad (2.25)$$

Das Interdependenzmaß $H^{(k)}$ wird dann mit Hilfe von 2.20 wie folgt definiert [AGLE99]:

$$H^{(k)}(X|Y) = \frac{1}{M_r} \sum_{n=1}^{M_r} \log \frac{R_n(X)}{R_n^{(k)}(X|Y)}. \quad (2.26)$$

Wenn die Systeme X und Y unabhängig sind, so gilt $R_n(X) \approx R_n^{(k)}(X|Y)$, so daß $H^{(k)}(X|Y) \approx 0$. Im Gegensatz zu $S^{(k)}$ kann $H^{(k)}$ negativ werden, wenn benachbarte Vektoren in Y gerade weit entfernte Vektoren in X bedingen. Die obere Schranke für $H^{(k)}$ ist nicht allgemeingültig wie die von $S^{(k)}$ und wird systemabhängig durch das Verhältnis von den Abständen der globalen Nachbarschaft $R_n(X)$ zu den Abständen der lokalen Nachbarschaft $R_n^{(k)}(X|Y)$ bestimmt.

⁴Für stochastische Dynamiken gilt $m = d_e$

⁵In der vorliegenden Arbeit wurde durchgängig jeweils eine Stichprobe von 40 Vektoren genommen, um $R_n(X)$ zu berechnen.

2.5.3 Interdependenzmaß N

Da $H^{(k)}$ den Nachteil aufweist, keine allgemeingültige obere Schranke zu haben, wurde in [QKKG02] durch eine andere Art der Mittelung als eine Weiterentwicklung von $H^{(k)}$ das Interdependenzmaß $N^{(k)}$ vorgestellt:

$$N^{(k)}(X|Y) = \frac{1}{M_r} \sum_{n=1}^{M_r} \frac{R_n(X) - R_n^{(k)}(X|Y)}{R_n(X)}. \quad (2.27)$$

Für identische Systeme gilt $N^{(k)} \rightarrow 1$. Wie nahe sich $N^{(k)}$ dabei 1 annähert, hängt wiederum vom Verhältnis der Abstände der globalen Nachbarschaft $R_n(X)$ zu den Abständen der lokalen Nachbarschaft $R_n^{(k)}(X|Y)$ ab. Für unabhängige Systeme kann $N^{(k)}$ aus dem gleichen Grund wie $H^{(k)}$ negativ werden.

2.5.4 Theiler-Korrektur

Zeitlich aufeinanderfolgende Zustandsraumvektoren sind mit hoher Wahrscheinlichkeit auch räumlich benachbart. Diese Nachbarschaft enthält jedoch keine für Interdependenzmaße relevante Information über die topologischen Eigenschaften des Zustandsraumes. Daher werden bei der Bestimmung der räumlichen Nachbarn für alle Interdependenzmaße Zustandsraumvektoren innerhalb einer zeitlichen Umgebung ausgeschlossen. Abhängig von der Abtastrate der Zeitreihen, wird durch die *Theiler-Korrektur* [The86] also ein zeitlicher Mindestabstand Λ vorgegeben, so daß folgende Randbedingung gilt:

$$|n - r_{n,j}| > \Lambda^{(X)} \quad (2.28)$$

$$|n - s_{n,j}| > \Lambda^{(Y)} \quad (2.29)$$

2.5.5 Asymmetrie

Alle genannten Interdependenzmaße sind asymmetrisch, d.h. es gilt

$$\begin{aligned} S^{(k)}(X|Y) &\neq S^{(k)}(Y|X) \\ H^{(k)}(X|Y) &\neq H^{(k)}(Y|X) \\ N^{(k)}(X|Y) &\neq N^{(k)}(Y|X). \end{aligned} \tag{2.30}$$

Arnhold et al. [AGLE99] konnten für $S^{(k)}$ zeigen, daß $S^{(k)}(X|Y) > S^{(k)}(Y|X)$ falls System X unidirektional und schwach System Y treibt. Dazu wird zunächst angenommen, daß ein zukünftiger Zustand des Systems Y als Funktion $\vec{\Omega}_a$ der Zustände der beiden Systeme X und Y ausgedrückt werden kann:

$$\vec{y}_{n+1} = \vec{\Omega}_a(\vec{x}_n, \vec{y}_n). \tag{2.31}$$

Handelt es sich um rauschfreie Systeme, so kann $\vec{\Omega}_a$ zumindest lokal invertiert werden:

$$\vec{x}_n = \vec{\Omega}_b(\vec{y}_n, \vec{y}_{n+1}). \tag{2.32}$$

Würde System Y nun mit einer höheren Dimension m eingebettet, gilt nach [SSC⁺96]

$$\vec{x}_n = \vec{\Omega}_c(\vec{y}_n). \tag{2.33}$$

Daraus folgt, daß eine Nachbarschaft von \vec{y}_n eine Nachbarschaft von \vec{x}_n bedingt. Eine umgekehrte Abhängigkeit läßt sich im Allgemeinen nicht aufstellen. Daraus folgt, daß die Y -konditionierten Abstände in System X , $R_n^{(k)}(X|Y)$, tendenziell weniger von $R_n^{(k)}(X)$ abweichen als für den umgekehrten Fall und somit $S^{(k)}(X|Y) > S^{(k)}(Y|X)$. Diese Argumentation gilt in analoger Weise für die Maße $H^{(k)}$ und $N^{(k)}$.

Um Stärke bzw. Richtung von Kopplungen zwischen zwei Systemen X und Y zu messen, werden für die asymmetrischen $S^{(k)}$, $H^{(k)}$ und $N^{(k)}$ jeweils symmetrische und antisymmetrische Maße konstruiert:

$$\begin{aligned}
 S_s^{(k)}(X|Y) &= \frac{S^{(k)}(X|Y) + S^{(k)}(Y|X)}{2} \\
 S_a^{(k)}(X|Y) &= \frac{S^{(k)}(X|Y) - S^{(k)}(Y|X)}{2} \\
 H_s^{(k)}(X|Y) &= \frac{H^{(k)}(X|Y) + H^{(k)}(Y|X)}{2} \\
 H_a^{(k)}(X|Y) &= \frac{H^{(k)}(X|Y) - H^{(k)}(Y|X)}{2} \\
 N_s^{(k)}(X|Y) &= \frac{N^{(k)}(X|Y) + N^{(k)}(Y|X)}{2} \\
 N_a^{(k)}(X|Y) &= \frac{N^{(k)}(X|Y) - N^{(k)}(Y|X)}{2}.
 \end{aligned} \tag{2.34}$$

2.6 Synchronisationsregime

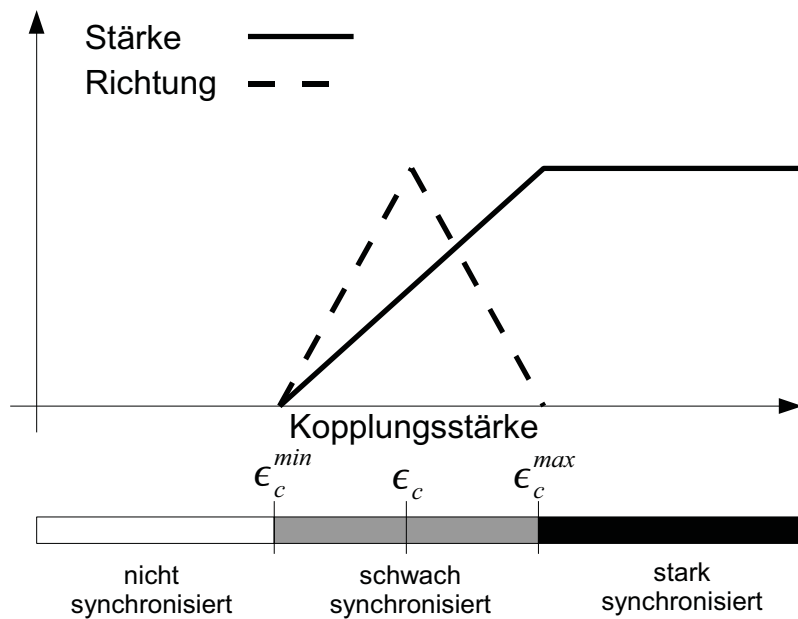


Abbildung 2.1: Idealisierte Verläufe von Stärke- und Richtungsmaßen in Abhängigkeit der unidirektionalen Kopplungsstärke zwischen zwei dynamischen Systemen.

Werden zwei dynamische Systeme, wie in Abschnitt 2.2 beschrieben, mit einer Kopplungsstärke ϵ gekoppelt, so lassen sich drei verschiedene Synchronisationsregime unterscheiden [Ost08] (siehe auch Abbildung 2.1). Für sehr kleine Kopplungsstärken unterhalb einer kritischen Kopplungsstärke $\epsilon < \epsilon_c^{min}$ sind die Systeme weitgehend unabhängig voneinander. Dies äußert sich in kleinen Werten für symmetrische Interdependenzmaße. Eine Information über eine Kopplungsrichtung lässt sich dagegen nicht aus den Zeitreihen bestimmen. Wird die Kopplungsstärke erhöht, kann eine Interaktion zwischen den Systemen anhand ihrer Zeitreihen gemessen werden. Maße für Interaktionsstärke steigen im Bereich $\epsilon_c^{min} < \epsilon < \epsilon_c^{max}$ kontinuierlich an. Dieser Bereich wird auch intermittent genannt [PST93, OS94]. Maße zur Detektion einer Kopplungsrichtung fallen für steigende Kopplungsstärken nach einem Extremum wieder ab. Dies ist auf die sich zunehmend angleichenden Systemdynamiken zurückzuführen, die zu immer ähnlicher werdenden Zeitreihen führen. Oberhalb der kritischen Kopplungsstärke $\epsilon > \epsilon_c^{max}$ sind die Systeme synchronisiert. Maße für Kopplungsstärke nehmen hier ihren Maximalwert an während aufgrund aneinander angepasster Systemdynamiken eine Detektion einer Interaktionsrichtung nicht mehr möglich ist.

3 Künstliche neuronale Netze

Bei künstlichen neuronalen Netzen (KNN) handelt es sich um informationsverarbeitende Systeme, welche durch die hohe Leistungsfähigkeit biologischer neuronaler Netze inspiriert sind. Bei letzteren dienen häufig die hoch entwickelten Zentralnervensysteme der Wirbeltiere und hier insbesondere das menschliche Gehirn¹ als Vorlage. Im folgenden Kapitel wird zunächst motiviert, welche Vorteile die Verarbeitung von Informationen mit neuronalen Netzen birgt. Anschließend werden verschiedene Modelle künstlicher neuronaler Netze vorgestellt und die Eigenschaften der in der vorliegenden Arbeit benutzten Zellularen Neuronalen Netze erläutert. Abschließend wird die Notwendigkeit und Umsetzung eines Optimierungsverfahrens zum Erlernen von Aufgabenstellungen diskutiert.

3.1 Biologische neuronale Netze

Ein neuronales Netz ist ein System, welches Informationen massiv parallel in stark untereinander vernetzten und vergleichsweise einfachen Einheiten verarbeitet. Das Paradebeispiel eines biologischen neuronalen Netzes ist selbstverständlich das menschliche Gehirn. Die informationsverarbeitenden Einheiten stellen hier die 10^{10} bis 10^{11} Neurone dar. Diese können physiologisch grob in die drei Komponenten Soma, Dendriten sowie Axone unterteilt werden. Das Soma - der Zellkörper eines Neurons - beinhaltet unter anderem die Energiequellen der Zellen, die Mitochondrien, und produziert Neurotransmitter. Zwischen Innen- und Außenseite eines Neurons, die durch eine Membran getrennt sind, herrscht aufgrund unterschiedlicher Ionenkonzentrationen ein Membranpotential. Wenn das Neuron inaktiv ist, wird dieses auch Ruhepotential genannt und beträgt etwa -70 mV. Durch plasmatische Verästelungen - die Dendriten - können Signale z.B. in Form von Potentialänderungen aus der Umgebung empfangen werden, welche sowohl hemmend als auch anregend sein können. Übersteigt das Membranpotential - also die Summe aus Ruhepotential, anregenden Potentialen und hemmenden Potentialen -

¹Ebenfalls könnte hier das hoch entwickelte Gehirn von Tintenfischen oder genauso die Ganglien von Insekten als Vorbild herangezogen werden.

einen Schwellenwert, so wird im Soma ein Aktionspotential nach dem Alles-oder-Nichts-Prinzip erzeugt. Dieses Aktionspotential wird über das Axon des Neurons weitergegeben. Andere Neurone, deren Dendriten durch Synapsen mit diesem Axon verbunden sind, können somit dieses Signal empfangen und ihrerseits verarbeiten. Das erwachsene menschliche Gehirn besitzt etwa 10^{14} Synapsen, also etwa 10^3 bis 10^4 Synapsen pro Neuron.

3.2 Motivation für künstliche neuronale Netze

Das menschliche Gehirn übertrifft die Leistungsfähigkeit von modernen Computern bei der Verarbeitung von Informationen in vielen Bereichen. Ganz besonders effektiv arbeitet das Gehirn beispielsweise bei kognitiven Aufgaben wie dem Erkennen von bekannten Gesichtern oder der Spracherkennung. Dabei verbraucht es mit etwa 15W bis 20W chemischer Leistung zudem nur einen Bruchteil der Energie eines PC-Prozessors der von Neumann-Architektur (je nach Modell etwa 100W).

Die Anzahl der informationsverarbeitenden Einheiten, sprich der Neurone im Gehirn bzw. der Transistoren eines Chips, ist hierbei eher zweitrangig. Beispielsweise bestehen die Nervensysteme einer Fliege aus etwa 10^5 Neuronen und das eines Hundes aus $1,6 \cdot 10^8$ Neuronen [RD05], mit denen so komplexe Aufgaben wie Kognition, Flugsteuerung, soziales Verhalten etc. zuverlässig gesteuert werden können. Dagegen ist ein moderner Prozessor mit zur Zeit knapp 10^9 Transistoren bei weitem nicht in der Lage, diese Aufgaben ähnlich effektiv zu lösen. Vielmehr liegt der wesentliche Unterschied in der massiv parallelen Verarbeitung bei neuronalen Netzen im Gegensatz zur sequentiellen Abarbeitung eines Programms bei der von Neumann-Architektur. Die starke Vernetzung von Neuronen durch Synapsen führt dazu, daß Informationen an verschiedenen Stellen gleichzeitig verarbeitet werden können.

Ein weiterer wesentlicher Unterschied ist das Vermögen, neue Aufgaben zu erlernen. Während für ein Computerprogramm Anweisungen Schritt für Schritt formuliert werden müssen, die für alle denkbaren Eingangsdaten das gewünschte Ergebnis liefern, lernen neuronale Netze eine neue Aufgabe anhand von Beispielen. Dabei werden anhand dieser Beispiele Regeln abgeleitet, die bei erfolgreichem Lernen auch für unbekannte Eingangsdaten funktionieren [WRB93]. Ein neuronales Netz besitzt also *Generalisierungseigenschaften*. Daher sind neuronale Netze besonders für komplexe Aufgaben, für die keine Formulierung durch ein endliches Computerprogramm entwickelt werden kann, geeignet.

Künstliche neuronale Netze versuchen nun, die wesentlichen Eigenschaften biolo-

gischer neuronaler Netze für die Informationsverarbeitung auszunutzen. Je nach Modell werden diese mehr oder weniger genau nachgebildet, so daß entsprechend die genannten Vorteile mehr oder weniger effektiv ausgenutzt werden können. So kann sich ein neuronales Netz beispielsweise im laufenden Betrieb durch Änderung der Synapsen (Erzeugung, Vernichtung, Anpassung der Stärke) an veränderte Anforderungen adaptieren und ist somit für nichtstationäre Probleme geeignet. Abschließend sei noch erwähnt, daß im Falle künstlicher neuronaler Netze häufig von *Zellen* und *Kopplungen* statt von Neuronen und Synapsen gesprochen wird, was die Abgrenzung zu biologischen neuronalen Netzen verdeutlichen soll.

3.3 Entwicklung künstlicher neuronaler Netze

Die Entwicklung der künstlichen neuronalen Netze begann 1943 durch die Mathematiker Warren McCulloch und Walter Pitts als diese die McCulloch-Pitts-Zelle als künstliche Analogie eines neurobiologischen Neurons einführten [MP43]. Eine solche Zelle kann zwei Zustände 1 (aktiv) und 0 (inaktiv) annehmen und erhält als Eingangsinformationen Signale von anregenden und hemmenden Leitungen. Überschreitet die Summe der anregenden Signale einen Schwellenwert, so ist der Zustand der Zelle 1 sofern nicht an mindestens einer hemmenden Leitung der Zustand 1 anliegt.

Der nächste Meilenstein wurde vom Psychologen Donald Olding Hebb 1949 gesetzt. Er beschrieb den Mechanismus der synaptischen Plastizität, sprich dem Verstärken oder Abschwächen von synaptischen Verbindungen zwischen Neuronen [Heb49]. Die Regel, die er dabei ableitete, lautet:

Wenn ein Axon der Zelle A [...] Zelle B erregt und wiederholt und dauerhaft zur Erzeugung von Aktionspotentialen in Zelle B beiträgt, so resultiert dies in Wachstumsprozessen oder metabolischen Veränderungen in einer oder in beiden Zellen, die bewirken, dass die Effizienz von Zelle A in Bezug auf die Erzeugung eines Aktionspotenzials in B größer wird.

Durch die Kombination von McCulloch-Pitts-Zellen und veränderbaren Kopplungsgewichten war es 1958 Frank Rosenblatt, der mit dem *Perzeptron* die Grundlage der künstlichen neuronalen Netze von heute bereitstellte [Ros58].




Abbildung 3.1: Schematische Darstellung einer Perzeptronzelle.

Perzeptron Das einfachste Perzeptron besteht aus lediglich einer Zelle (siehe Abbildung 3.1). Es werden die Eingangssignale $g_{p,1}, \dots, g_{p,n}$ jeweils mit den Kopplungsgewichten $w_{p,1}, \dots, w_{p,n}$ gewichtet. Dann gilt:

$$z_p = \sum_{i=1}^n w_{p,i} g_{p,i} + s_p \quad (3.1)$$

Mit der Heavisidefunktion $\Theta(z_p)$ entspricht s_p dem Schwellenwert, der überschritten werden muß, um die Zelle zu aktivieren, d.h. einen Ausgabewert von $v_p = 1$ zu erzeugen. Dies lässt sich entsprechend auf ein Perzeptron mit mehreren Zellen erweitern (siehe Abbildung 3.2).

Üblicherweise wird ein solches Perzeptron als Klassifikator eingesetzt, der Eingangsdaten in zwei Klassen separieren soll. Für Eingangsdaten der einen Klasse soll die Ausgabe $v_p = 0$ sein und für die Daten der anderen Klasse $v_p = 1$. Da die Diskriminanzfunktionen lediglich Linearkombinationen der Eingänge sind, stellen einlagige Perzeptronen einen linearen Klassifikator dar. Folglich kann ein einschichtiges Perzeptron auch nur linear separierbare Probleme lösen, sprich eine Hyperebene in den Ergebnisraum als Trennschicht einführen. Das prominenteste Beispiel eines für ein einschichtiges Perzeptron unlösbaren Problems ist die logische Funktion XOR. Als Lösung eignen sich mehrlagige Perzeptrone mit versteckten Verarbeitungsschichten (siehe Abbildung 3.3). Mit dieser Erweiterung lassen sich ebenfalls nicht linear separierbare Probleme mit einem Perzeptron lösen. So erlauben Perzeptrone mit zwei Verarbeitungsschichten konvexe Polygone als Diskriminanzfunktion. Schon dreilagige Perzeptrone sind in der Lage, beliebige Mengen zu klassifizieren.




Abbildung 3.2: Einlagiges Perzeptron, links als Kreise sind die Eingänge dargestellt, die jeweils in alle vier Zellen (Quadrate) eingekoppelt sind.

Hopfieldnetz Ein anderes Modell künstlicher neuronaler Netze wurde 1982 vom Physiker John Hopfield eingeführt [Hop82]. Die Dynamik des Hopfield-Netzes ist physikalisch motiviert und beruht auf der Minimierung von Energiezuständen. So ist es möglich, das Ising-Modell zu realisieren und damit Spingläser zu simulieren [Hop82, Hop84, AG85]. Dabei besteht ein solches Netz aus McCulloch-Pitts-Zellen, wobei jede Zelle mit jeder anderen außer sich selbst symmetrisch gekoppelt ist. Als Aktivierungsfunktion dient die Signum-Funktion, wodurch jede Zelle zwei Zustände annehmen kann - beispielsweise Spin Up bzw. Spin Down beim erwähnten Ising-Modell. Die iterative Vorschrift zur Beschreibung der Dynamik einer Zelle $z_{h,i}(t)$ in einem Netz aus M_h Zellen lautet dann:

$$z_{h,i}(t) = \operatorname{sgn} \left(\sum_{j \neq i} w_{h,ij} z_{h,j}(t-1) \right) \quad \text{mit } i = 1, \dots, M_h. \quad (3.2)$$

Bei positiver Kopplung $w_{h,ij} > 0$ zweier Zellen ist es dann energetisch günstiger, wenn beide Zellen den gleichen Zustand annehmen - je größer $w_{h,ij}$, desto stärker der Zwang. Für $w_{h,ij} < 0$ gilt entsprechend, daß es günstiger ist, unterschiedliche Zustände anzunehmen. Für $w_{h,ij} = 0$ gibt es keinen Einfluss der Zellen aufeinander. Es kann nun gezeigt werden, daß in einem Hopfield-Netz eine Energiefunktion der Form




Abbildung 3.3: Mehrlagiges Perzeptron mit zwei Verarbeitungsschichten (die Zellen sind als Quadrate dargestellt), links als Kreise die Eingänge.

$$E = -\frac{1}{2} \sum_{i \neq j} w_{h,ij} z_{h,i} z_{h,j} + \sum_i \Theta_i z_{h,i} \quad (3.3)$$

existiert, welche mit jedem Zeitschritt abnimmt, bis alle Zellen einen stabilen Zustand angenommen haben.

3.4 Zellulare Neuronale Netze (CNN)

Die meisten künstlichen neuronalen Netze besitzen eine sehr komplexe Kopplungstopologie wie beispielsweise die Hopfield-Netze (siehe Abschnitt 3.3), bei denen keine Einschränkung für die Anordnung der Zellen existiert und per Definition jede Zelle mit jeder anderen gekoppelt ist. Dies führt dazu, daß einerseits die mathematische Beschreibung durch Differentialgleichungen recht komplex werden kann und insbesondere deren numerische Lösung große Ressourcen benötigt. Andererseits sind hardwaretechnische Realisationen stark durch die verfügbaren Fertigungstechniken eingeschränkt oder zu unflexibel.

Chua und Yang schlugen daher 1988 das Paradigma des Zellularen Neuronalen Netzes (im folgenden mit CNN von Cellular Neural Network abgekürzt) vor [CY88b, CY88a]. Dabei lag die Annahme zugrunde, daß verschiedene dynamische Phänomene mit nur *lokal gekoppelten* und *relativ einfachen* nichtlinearen Baustei-

nen - Zellen genannt - reproduziert werden können². Hinzu kam die pragmatische Motivation, ein Modell eines künstlichen neuronalen Netzes zu entwickeln, welches, im Gegensatz zu den eher theoretisch motivierten, einfach genug ist, um es hardwaretechnisch umsetzen zu können.

Dies wird einerseits durch die lediglich lokalen Kopplungen zwischen den Zellen erreicht. Hinzu kommt bei einem *Standard-CNN* die zusätzliche Einschränkung, daß die $M = M_x \times M_y$ Zellen auf einem regulären Gitter angeordnet sind. Im Folgenden ist mit CNN immer ein Standard-CNN gemeint.




Abbildung 3.4: Schematische Darstellung eines Standard-CNN. Die Zellen sind auf einem Gitter angeordnet und nur lokal miteinander gekoppelt.

Weiterhin ist das Kopplungsschema der Zellen translationsinvariant und ein CNN stellt somit ein homogenes Medium dar. Dies hat den Vorteil, daß die zeitliche Entwicklung sämtlicher Zellen von einer einzigen Bewegungsgleichung abhängt, welche vollständig durch eine vergleichsweise kleine Menge reeller Zahlen - den Kopplungskoeffizienten - bestimmt wird (siehe Abschnitt 3.4.5). Ein wesentliches Merkmal, welches CNN von Rechnern der von Neumann-Architektur unterscheidet, ist, daß diese Zustandsgleichung kontinuierlich ist. Dadurch kann ein CNN als ein Netz aus analogen Prozessoren aufgefasst werden, was sehr energieeffiziente hardwaretechnische Implementierungen ermöglicht [LPKH02, LPKH04, RLC⁺04].

Diese Architektur von analogen Prozessoren als homogenes Medium hat weitreichende Konsequenzen für die Art der Informationsverarbeitung. So ist im Gegensatz zu Rechnern der von Neumann-Architektur die Verarbeitung von Information

²Wenn CNN als Generatoren einer nichtlinearen Dynamik eingesetzt werden, so wird auch von Cellular Nonlinear Networks gesprochen, um eine sprachliche Abgrenzung zum Einsatz als Berechnungswerkzeug herzustellen.

nicht nur durch einen nicht mehr veränderbaren Endzustand charakterisiert (nach n Verarbeitungsschritten durch einen Algorithmus) sondern vielmehr durch die Dynamik des Netzes. Abhängig von Eingangsdaten und Kopplungsgewichten können die Zellzustände einerseits ebenfalls einen festen Zustand erreichen, darüber hinaus aber auch oszillatorisches oder gar chaotisches Verhalten zeigen [Chu98]. In diesem Zusammenhang ist ebenfalls die Frage zu beantworten, inwiefern Problemstellungen, die zumindest teilweise auf globalen Eigenschaften beruhen, durch ein CNN mit nur lokaler Konnektivität gelöst werden können. Hier zeigte Chua [Chu98], daß Informationen in CNN wie Wellen durch ein homogenes Medium wandern, indem er das Problem der globalen Konnektivität³ mit einem Standard-CNN löste, welches mit beispielsweise Perzeptronen nicht möglich ist.

Hierbei wird deutlich, daß völlig neue Interpretationstechniken benötigt werden, wenn auch aus der Dynamik eines CNN Informationen gewonnen werden sollen, was zur Zeit ein lebendiges Forschungsgebiet darstellt. Aus diesem Grund wird seit kurzem in verschiedenen Anwendungen von *Cellular Wave Computing* gesprochen, wenn Daten mit CNN verarbeitet werden [Ros05, ERRN06, Ros07, ERRN08, Ros08, RALT09]. Da allerdings bis heute keine umfassende Beschreibung der verschiedenen Phänomene verfügbar ist, wurde in der vorliegenden Arbeit ein klassischer Weg gewählt, indem die Informationsverarbeitung durch das Netz nach einer gewissen transienten Zeitspanne τ_{trans} gestoppt wird und dieser Zustand als Ergebnis dient, worauf später noch detailliert eingegangen werden wird.

Ein wichtiger Aspekt von CNN ist die *Universalität*. Hierzu führte Chua zunächst die CNN Universal Machine ein [CRV93, Chu98], einen CNN-Chip mit Speicherregistern, welcher Programmierbarkeit besitzt. Dies bedeutet, daß analog zu einem Computerprogramm verschiedene CNN Operationen nacheinander ausgeführt werden und Zwischenergebnisse gespeichert werden können. Um zu zeigen, daß diese CNN-UM eine universelle Turingmaschine ist⁴, wird der Umweg über das Game Of Life⁵ gegangen. Da gezeigt wurde, daß ein Game Of Life Automat eine universelle Turingmaschine ist und die CNN-UM in der Lage ist, dieses zu simulieren, wurde gefolgert, daß eine CNN-UM selber eine universelle Turingmaschine ist [Chu98].

³Beim Problem der globalen Konnektivität [MP69] geht es darum, festzustellen, ob geometrische Strukturen verbunden oder getrennt sind.

⁴Eine universelle Turingmaschine ist ein programmierbarer Automat, von dem die Church-Turing-These behauptet, daß er gerade die von Menschen berechenbaren Funktionen lösen kann.

⁵Das Game Of Life wurde vom Mathematiker John Horton Conway entwickelt. Es ist ein Programm, welches auf einem zweidimensionalen zellulären Automaten läuft und bei dem die Zellen die Zustände „tot“ oder „lebendig“ annehmen können. Eine Zelle ist in der nächsten Generation genau dann „lebendig“, wenn zwei oder drei Nachbarzellen „lebendig“ sind. Ansonsten kommt es zum „Tod“ durch „Einsamkeit“ oder „Überbevölkerung“.

3.4.1 Isolierte Zelle

Die von Chua gegebene Definition eines CNN lautet - frei übersetzt - wie folgt:

„Ein CNN ist eine beliebige räumliche Anordnung von *lokal gekoppelten* Zellen, welche jeweils ein dynamisches System mit einem *Eingang*, einem *Ausgang* und einem *Zustand* - der sich gemäß eines dynamischen Gesetzes entwickelt - darstellen.“

Eine isolierte einzelne Zelle mit Eingang $g_{ij}(t)$, Zustand $z_{ij}(t)$, Ausgang $v_{ij}(t)$ und Schwellenwert $s_{ij}(t)$ kann also schematisch folgendermaßen dargestellt werden:




Abbildung 3.5: Schematische Darstellung einer isolierten Zelle eines CNN.

Prinzipiell können alle Variablen der Zelle zeitlich abhängig sein, wobei in den meisten Anwendungen der Eingang g_{ij} sowie der Schwellenwert s_{ij} konstant sind. Dies ist hauptsächlich damit begründet, daß - wie oben erwähnt - das Netz nach einer transienten Zeit einen stabilen Endzustand annehmen soll, der dann das Ergebnis repräsentiert. Dynamische Parameter lassen das Netz im allgemeinen nie einen festen Zustand annehmen, so daß als Ergebnis eine Interpretation der Dynamik erfolgen müsste.

3.4.2 Aktivierungsfunktion

Die *Aktivierungsfunktion* f bestimmt die Ausgabe $v_{ij}(t)$ einer Zelle. Prinzipiell kann die Aktivierungsfunktion von sämtlichen Variablen einer Zelle abhängen $v_{ij}(t) = f(z_{ij}(t), g_{ij}(t), s_{ij}(t))$, wobei in den allermeisten Anwendungen lediglich der Zustand der Zelle von Belang ist: $v_{ij}(t) = f(z_{ij}(t))$. Eine wesentliche Aufgabe der Aktivierungsfunktion ist die Beschränkung der Amplitude der Ausgabe $v_{ij}(t)$, da diese sonst unter Umständen unbeschränkt ansteigen könnte. Für die Wahl einer Aktivierungsfunktion gibt es verschiedene Möglichkeiten, wovon die am häufigsten verwendeten kurz vorgestellt werden sollen:

Stufenfunktion

$$v_{ij}(t) = f(z_{ij}(t)) = \begin{cases} 1, & \text{falls } z_{ij}(t) \geq 0 \\ -1, & \text{falls } z_{ij}(t) < 0 \end{cases} \quad (3.4)$$

Die Stufenfunktion erlaubt lediglich zwei Ausgangszustände und ist somit nur für bestimmte Anwendungen geeignet.

Stückweise lineare Funktion

$$v_{ij}(t) = f(z_{ij}(t)) = \frac{1}{2} (|z_{ij}(t) + 1| - |z_{ij}(t) - 1|) \quad (3.5)$$

Eine stückweise lineare Aktivierungsfunktion kann im mittleren Bereich verschiedene Zustände differenzieren und kontinuierliche Ausgabeamplituden v_{ij} erzeugen. Ist der Zellzustand größer bzw. kleiner als jeweils ein Grenzwert (an dem die Funktion nicht differenzierbar ist), nimmt die Funktion konstant den maximalen bzw. minimalen Wert an.

Sigmoidale Funktion Sigmoidale Funktionen werden im Bereich der künstlichen neuronalen Netze am häufigsten als Aktivierungsfunktion eingesetzt. Dies liegt unter anderem an ihrer Differenzierbarkeit, welches die theoretische Behandlung im Gegensatz zu einer beispielsweise stückweise linearen Funktion wesentlich erleichtert. Darüber hinaus lassen sich sigmoidale Aktivierungsfunktionen gut hardwaretechnisch realisieren, da sie der Transistorkennlinie ähneln.

$$v_{ij}(t) = f(z_{ij}(t)) = \frac{2}{1 + e^{-\delta z_{ij}(t)}} - 1 \quad (3.6)$$

In der vorliegenden Arbeit wurde durchgängig eine sigmoidale Aktivierungsfunktion mit einem Steigungsparameter $\delta = 4$ verwendet [SCML05, KOEL07].

3.4.3 Einflussumgebung

Eine Zelle ist lokal mit allen Zellen verbunden, welche innerhalb einer *Einflussumgebung* L_{ij} mit einem Radius r um die Zelle herum liegen. Üblicherweise wird r so gewählt, daß nur die direkten nächsten Nachbarn (horizontal, vertikal sowie diagonal) eingekoppelt werden. Dies entspricht dann einer 3×3 Zellen großen Einflussumgebung.

Ebenfalls sind größere Einflussumgebungen möglich, jedoch unter Umständen mit Problemen behaftet. Beispielsweise sind hardwaretechnische Implementierungen schwieriger zu realisieren. Darüber hinaus erschweren die zusätzlichen Kopplungen unter Umständen das Erlernen von Aufgabenstellungen (siehe Abschnitt 3.5) für das Netz.

3.4.4 Randbedingungen

Für Randzellen liegt die Einflussumgebung teilweise außerhalb des Netzwerkes. Hier werden daher *virtuelle Zellen* eingekoppelt, deren Verhalten durch verschiedene Randbedingungen definiert werden kann:

Neutral, Dirichlet Der Zustand der virtuellen Zellen wird auf einen konstanten Wert festgesetzt.

Zero Flux, Neumann Die virtuelle Zelle übernimmt den Zustand der senkrecht im Netz liegenden benachbarten Zelle.

Periodisch, Torus Die virtuelle Zelle übernimmt den Zustand der Randzelle auf der gegenüberliegenden Seite des Netzwerkes. Somit werden die Randzellen miteinander verbunden, wodurch ein Torus entsteht.

Periodisch, Spirale Ähnlich wie beim Torus werden die Zellen von gegenüberliegenden Rändern miteinander verbunden, jedoch mit einem Zeilen- bzw. Spaltenversatz von 1. Somit entsteht eine spiralartige Topologie.

3.4.5 Zustandsgleichung und Kopplungsgewichte

Mit den oben eingeführten Elementen eines CNN kann nun die *Zustandsgleichung* definiert werden, welche die zeitliche Entwicklung der Zellen beschreibt:




Abbildung 3.6: Schematische Darstellung der Feedback- (links) und Feedforward-Synapsen (rechts): Die Ausgaben bzw. die Eingänge der Zellen in der Einflussumgebung werden in die mittlere Zelle eingekoppelt.

$$C_{ij}\dot{z}_{ij}(t) = \frac{-z_{ij}(t)}{R_{ij}} + \sum_{n=1}^p \sum_{kl \in L_{ij}^{(a)}} a_{kl,n}(v_{kl}(t))^n + \sum_{n=1}^p \sum_{kl \in L_{ij}^{(b)}} b_{kl,n}(g_{kl})^n + s_{ij}. \quad (3.7)$$

Die hier angegebene und in der vorliegenden Arbeit durchgängig verwendete Gleichung repräsentiert ohne Beschränkung der Allgemeinheit den 2-dimensionalen Fall mit Zellindizes ij mit $i = 1, \dots, M_x$ und $j = 1, \dots, M_y$. Die Entwicklung des Zustandes $z_{ij}(t)$ einer Zelle hängt zunächst also von dem Zustand der Zelle selbst ab. Wird auf der rechten Seite von Gleichung 3.7 nur der erste Summand betrachtet, so entspricht die Gleichung dem Laden eines Kondensators, was ebenfalls durch den Widerstand R_{ij} sowie die Kapazität C_{ij} der Zelle deutlich wird. Ohne Beschränkung der Allgemeinheit wird in der vorliegenden Arbeit durchgängig $R_{ij} = C_{ij} = 1 \forall i, j$ gesetzt.

Die erste Doppelsumme beschreibt die *Feedback*-Kopplungen und die zweite die *Feedforward*-Kopplungen (siehe auch Abbildung 3.6). Die jeweils erste Summation legt dabei den polynomiellen Grad p der Kopplungen fest. Die zweite Summe läuft über alle Zellen der Einflussumgebungen $L^{(a)}$ bzw. $L^{(b)}$, die in der vorliegenden Arbeit für Feedback- und Feedforward-Kopplungen identisch sein sollen, also $L^{(a)} = L^{(b)} = L$. Der Schwellenwert ist üblicherweise translationsinvariant, so daß $s_{ij} = s \forall i, j$ gilt.

Aus Gleichung 3.7 kann abgelesen werden, daß das Verhalten eines CNN für gegebene Eingabedaten lediglich von den Kopplungskoeffizienten $a_{kl,n}$ sowie $b_{kl,n}$ und dem Schwellenwert s abhängt. Da die Kopplungsgewichte genau wie der Schwellenwert

translationsinvariant sind, ergeben sich für 3×3 -Einflussumgebungen der Ordnung $p = 1$ lediglich $3 \times 3 + 3 \times 3 + 1 = 19$ Parameter⁶. Durch das Konzept der lokalen Kopplung und der Translationsinvarianz (homogenes Medium) hängt die Anzahl der Freiheitsgrade nicht von der Anzahl der Zellen ab.

Die Menge der Feedforward- bzw. der Feedback-Kopplungen werden auch Feedforward- bzw. Feedback-*Templates* genannt. Der Einfachheit halber wird im Folgenden nur noch von einem Template gesprochen, wobei die Feedforward- bzw. Feedback-Kopplungen sowie der Schwellenwert - also ein Satz von Parametern des Netzes - gemeint sind.

3.5 In-Sample Optimierung der Kopplungsgewichte

Wie oben beschrieben, hängt die Funktionalität eines CNN von den Kopplungsgewichten und dem Schwellenwert, also seinem Template, ab. Für einfache Aufgaben⁷ kann das System aus gekoppelten Zustandsgleichungen unter Umständen analytisch gelöst werden, so daß ein geeignetes Template berechnet werden kann. Hierfür muß allerdings eine allgemeine Regel formuliert werden können, nach der sich die gewünschte Ausgabe aller möglichen Eingaben ableitet, was im Allgemeinen meist nicht möglich ist.

Daher muß auf ein iteratives Optimierungsverfahren zurückgegriffen werden. Im Wesentlichen lassen sich zwei Optimierungsarten unterscheiden: Überwachtes und unüberwachtes Lernen. Im letzteren Fall versucht das neuronale Netz, selbstständig die Trainingsdaten anhand ihrer Eigenschaften zu klassifizieren (beispielsweise bei einem Kohonennetz bzw. Selbstorganisierenden Karten [Koh82]).

Als Grundlage eines überwachten Optimierungsverfahrens dient eine sog. *Trainingsmenge* T , deren M_{tr} Elemente jeweils eine Instanz der Aufgabenstellung repräsentieren. Jedes Element besteht also aus den Daten in der Form, in der sie dem CNN präsentiert werden (Zelleingänge g_{ij} , Zell-Anfangszustände $z_{ij}(0)$), sowie dem gewünschten Ergebnis - der *Referenz* (gewünschte Zellausgänge $v_{ij}^{(r)}$). Es handelt sich also um eine *In-Sample Optimierung* innerhalb der Trainingsmenge:

⁶Zum Vergleich sei hier ein Hopfieldnetz mit $64 \times 64 = 4096$ Zellen erwähnt, welches $4096 \cdot (4096 - 1) = 16773120$ Kopplungen und somit ebensoviele Parameter besitzt.

⁷Einfach sind in diesem Zusammenhang beispielsweise Anwendungen von sog. autonomen CNN, d.h. CNN mit Zellen ohne Feedback-Kopplungen. Die Zustandsgleichungen sind dann nicht mehr gekoppelt und somit vergleichsweise einfach zu handhaben [Chu98].

$$\begin{aligned}
 T &= \{J_n\} \quad n = 1, \dots, M_{tr} \\
 J_n &= \{G_n, Z_n(0), V_n^{(r)}\}, \\
 \text{mit } G_n &= \{g_{ij,n}\}, \quad i = 1, \dots, M_x \quad j = 1, \dots, M_y \\
 Z_n(0) &= \{z_{ij,n}(0)\}, \quad i = 1, \dots, M_x \quad j = 1, \dots, M_y \\
 V_n^{(r)} &= \{v_{ij,n}^{(r)}\}, \quad i = 1, \dots, M_x \quad j = 1, \dots, M_y.
 \end{aligned} \tag{3.8}$$

Die Zusammenstellung der Trainingsmenge ist von entscheidender Bedeutung für eine erfolgreiche Optimierung. Die Elemente sollten dabei das Spektrum aller möglichen Eigenschaften, die die Eingabedaten haben können, repräsentieren, da unbekannte Eigenschaften nicht adaptiert werden können und somit keine Generalisierung möglich ist. Darüber hinaus sollten die Elemente möglichst wenig irrelevante Gemeinsamkeiten aufweisen, da es sonst leicht zu einer *Übervoptimierung* kommen kann (siehe Abschnitt 3.5.2).

3.5.1 Minimierungsproblem

Die Güte eines Templates für die Daten eines Elementes der Trainingsmenge wird nun durch den Abstand der gewünschten Ausgabe $V_n^{(r)}$ und der tatsächlichen Ausgabe $V_n(\tau_{trans})$ bestimmt. Quantifiziert wird dies durch eine Fehlerfunktion F_n , welche *lokaler Fehler* genannt wird:

$$F_n = \frac{1}{M_x M_y} \sum_{i=1}^{M_x} \sum_{j=1}^{M_y} \left(v_{ij,n}^{(r)} - v_{ij,n}(\tau_{trans}) \right)^2. \tag{3.9}$$

Eine Bewertung für die gesamte Trainingsmenge erfolgt durch eine Mittelung über alle Elemente und wird als *globaler Fehler* bezeichnet:

$$F^{(g)} = \frac{1}{M_{tr}} \sum_{i=1}^{M_{tr}} F_i. \tag{3.10}$$

Die Suche nach einem minimalen *globalen Fehler* $F^{(g)}$ in dem Raum, der durch die Templateeinträge (Feedforward- und Feedback-Kopplungen sowie Schwellenwert) aufgespannt wird, ist ein klassisches Minimierungsproblem. Da jedoch meist

sehr viele Templateeinträge verwendet werden, besitzt der Raum eine entsprechend hohe Dimensionalität. Daher kann aufgrund der begrenzten zur Verfügung stehenden Rechenkapazität eine Suche durch eine gleichmäßige Abtastung des Raumes nicht durchgeführt werden, so daß auf einen geeigneten Minimierungsalgorithmus zurückgegriffen werden muß. Hierbei gibt es eine Vielzahl verschiedener Methoden, welche mehr oder weniger auf spezielle Eigenschaften des Parameterraums angepasst sind. Da die Beschaffenheit des Parameterraums für eine Trainingsmenge nur schwer eingeschätzt werden kann, wurde in der vorliegenden Arbeit auf einen evolutionären Algorithmus zurückgegriffen. Dieser gehört zu den stochastischen Minimierungsverfahren und benötigt daher beispielsweise keine Gradienteninformationen (detaillierte Beschreibung siehe Abschnitt 4.3.1).

3.5.2 Überanpassung, Testmenge

Ein ungewünschtes Phänomen, welches bei einer In-Sample Optimierung auftreten kann, ist eine *Überanpassung*. Ein CNN mit überangepassten Templates arbeitet mit den Daten der Trainingsmenge nahezu perfekt, besitzt aber nicht die gewünschten Generalisierungseigenschaften, da es nicht gemäß der zu trainierenden Regel arbeitet, sondern irrelevante Aspekte der Trainingselemente nutzt. In der Literatur existiert eine Anekdote, welche hierfür ein anschauliches Beispiel liefert⁸. Demnach plante das Pentagon in den 1980er Jahren die Entwicklung eines neuronalen Netzes, welches automatisiert Panzer auf Bildern erkennen sollte und dementsprechend mit Fotos von Wäldern mit und ohne Panzer trainiert wurde. Nach der Optimierungsprozedur konnte das Netz Fotos, die aus dem gleichen Satz stammten, jedoch nicht zur Optimierung benutzt wurden, nahezu perfekt klassifizieren. Bei unbekannten Fotos, die aus anderen Quellen stammten, war die Klassifizierung jedoch rein zufällig. Erst später fiel auf, daß sämtliche für die Optimierung verwendeten Aufnahmen mit Panzern bei bewölktem und trübem Wetter gemacht wurden und diejenigen ohne Panzer bei Sonnenschein. Das Netz hatte also eine entsprechende Wetterregel zur Generalisierung genutzt statt der Eigenschaft Panzer/kein Panzer. Dies kann damit erklärt werden, daß das Wetter beispielsweise ein identisches Lichtspektrum in jedem Bild hervorruft, während Bilder von unterschiedlich getarnten Panzern immer nur einen kleinen Teil des Bildes ausmachen und somit sehr subtile Eigenschaften im Bild entscheidend sind. Damit korrelieren dann vergleichsweise viele und auch weiter ausgedehnte Minima im Parameterraum mit der Klassifikati-

⁸Es sei erwähnt, daß es nicht möglich war, eine Ursprungsquelle ausfindig zu machen. Dennoch wird die Anekdote sehr häufig in der Literatur erwähnt (beispielsweise in [Han97, PK05, LW08]). Unabhängig davon, ob es tatsächlich so geschehen sein sollte, ist es doch ein realistisches und anschauliches Beispiel für die Probleme, die bei einer In-Sample Optimierung auftreten können.

on anhand des Wetters und eher wenige und scharf begrenzte mit der Klassifikation anhand der gewünschten Regel Panzer/kein Panzer. Erstgenannte wird also in den allermeisten Fällen den Optimierungsvorgang dominieren.

Die Zusammenstellung der Trainingsmenge sollte folglich so sein, daß relevante Eigenschaften in allen Elementen vorkommen, sämtliche irrelevante Eigenschaften aber so heterogen wie möglich verteilt sind. Dann ist es unwahrscheinlicher, ein zu irrelevanten Eigenschaften korreliertes Minimum im Parameterraum zu finden, verglichen mit der Wahrscheinlichkeit, ein Minimum zu finden, welches mit der gewünschten Regel korreliert. Da dies aber nie völlig ausgeschlossen werden kann und irrelevante Eigenschaften sehr subtil und auf den ersten Blick nicht erkennbar in Daten verborgen sein können, sollte nicht ohne Weiteres auf eine geeignete Auswahl von Elementen der Trainingsmenge vertraut werden.

Hier setzt das Konzept der *Testmenge* an:

$$\begin{aligned}
 T^{(test)} &= \{J_n^{(test)}\} \quad n = 1, \dots, M_{te} \\
 J_n^{(test)} &= \{G_n, Z_n(0), V_n^{(r)}\} \\
 \text{mit } G_n &= \{g_{ij,n}\}, \quad i = 1, \dots, M_x \quad j = 1, \dots, M_y \\
 Z_n(0) &= \{z_{ij,n}(0)\}, \quad i = 1, \dots, M_x \quad j = 1, \dots, M_y \\
 V_n^{(r)} &= \{v_{ij,n}^{(r)}\}, \quad i = 1, \dots, M_x \quad j = 1, \dots, M_y.
 \end{aligned} \tag{3.11}$$

Die Testmenge besteht wie die Trainingsmenge aus bekannten Instanzen der Aufgabenstellung mitsamt der gewünschten Lösung. Ebenso wie für die Trainingsmenge wird der globale Fehler $F^{(g,test)}$ (siehe Gleichung 3.10) jedes Templates für die Testmenge ebenfalls berechnet, jedoch nicht in die Optimierung der Parameter einbezogen. Eine Überoptimierung kann so durch eine gute Bewertung $F^{(g)}$ der Trainingsmenge in Verbindung mit einer schlechten Bewertung $F^{(g,test)}$ der Testmenge erkannt werden.

Darüber hinaus würden sich hier eventuell Kreuzvalidierungsverfahren anbieten. Es sei aber vorweggenommen, daß auf diese in der vorliegenden Arbeit aufgrund der damit verbundenen stark anwachsenden Rechenzeit verzichtet wurde.

3.5.3 Out-Of-Sample Validierung

Das erfolgreiche Auffinden eines Minimums im Parameterraum, welches ebenfalls eine gute Bewertung durch $F^{(g,test)}$ besitzt, ist allerdings noch immer keine Garantie für ein optimal arbeitendes CNN. Zunächst ist es fraglich, ob tatsächlich ein globales Minimum oder lediglich ein lokales Minimum gefunden wurde. Diese Frage kann jedoch nach einer Optimierung ohne Kenntnis des gesamten Parameterraums nur für den Fall $F^{(g)} = 0$ zuverlässig beantwortet werden. Darüber hinaus kann es trotz Verwendung einer Testmenge vorkommen, daß gerade bei den sehr guten Fehlerbewertungen eine Überoptimierung stattgefunden hat - beispielsweise aufgrund zu ähnlicher Trainings- und Testdaten oder zu weniger Elemente in Trainings- bzw. Testmenge.

Endgültigen Aufschluss über die Qualität eines Templates kann nur eine *Out-Of-Sample Validierung* bieten. Hierbei wird eine - verglichen mit $F^{(g)}$ und $F^{(g,test)}$ - wesentlich größere Menge von Instanzen mit Hilfe des optimierten CNN berechnet und der Abstand der CNN-Ausgabe von der gewünschten Ausgabe mit Hilfe eines Fehlermaßes bewertet. Dies führt zu einer statistisch sehr zuverlässigen Aussage, ob das trainierte CNN die gewünschten Generalisierungseigenschaften besitzt.

$$\begin{aligned}
 T^{(val)} &= \{J_n^{(val)}\} \quad n = 1, \dots, M_{val} \\
 J_n^{(val)} &= \{G_n, Z_n(0), V_n^{(r)}\} \\
 \text{mit } G_n &= \{g_{ij,n}\}, \quad i = 1, \dots, M_x \quad j = 1, \dots, M_y \\
 Z_n(0) &= \{z_{ij,n}(0)\}, \quad i = 1, \dots, M_x \quad j = 1, \dots, M_y \\
 V_n^{(r)} &= \{v_{ij,n}^{(r)}\}, \quad i = 1, \dots, M_x \quad j = 1, \dots, M_y.
 \end{aligned} \tag{3.12}$$

4 Charakterisierung von Synchronisationsphänomenen mit CNN

Bei der Analyse von Felddaten mit bivariaten Maßen führt die quadratische Abhängigkeit der zu berechnenden Kenngrößen von der Anzahl der Sensoren zu einem hohen Rechenaufwand. Beispielsweise benötigt trotz der konzeptionellen Einfachheit nichtlinearer Interdependenzmaße die Suche der nächsten Nachbarn im Zustandsraum große Ressourcen. Somit sind Analysen von Felddaten, die anhand von nichtlinearen Interdependenzmaßen Interaktionen zwischen dynamischen Systemen charakterisieren sollen, stark eingeschränkt. Hinzu kommt der hohe Energieverbrauch der Prozessoren sowie der Platzbedarf beispielsweise für Kühlungselemente. Künstliche neuronale Netze bieten hier möglicherweise eine Alternative zur Berechnung unter Ausnutzung der massiv parallelen Verarbeitung von Daten (siehe auch Kapitel 3). Dabei wurde die Eignung künstlicher neuronaler Netze beispielsweise zur Modellierung, Erzeugung und Vorhersage von, zum Teil auch chaotischen, Zeitreihen bereits gezeigt [APHF92, PRK92, EKKK95, KPP97, BSG⁺00, FKK02, ST02, CK04, CGC⁺05, PTPV06, GRG06]. Häufig sind die in künstlichen neuronalen Netzen notwendigen Kopplungstopologien so komplex, daß weder effektive Simulationen am Computer noch hardwaretechnische Realisierungen möglich sind. Daher wurde in der vorliegenden Arbeit auf Zellulare Neuronale Netze (CNN) zurückgegriffen, die sich durch lediglich lokale Zellkopplungen auszeichnen (siehe auch Abschnitt 3.4). Dies ermöglicht energieeffiziente hardwaretechnische Implementationen [LPKH02, LPKH04, RLC⁺04].

In den vergangenen Jahren konnte die Eignung von CNN für verschiedene univariate Methoden der Zeitreihenanalyse nachgewiesen werden. So wurde in [TKAW99] gezeigt, daß ein Schätzer der Korrelationsdimension [GP83] mit CNN approximiert werden kann. Darüber hinaus wurde die Eignung zur Messung von Stabilitätseigenschaften [Kra06] oder Komplexitätsänderungen [Wan07] in dynamischen Systemen nachgewiesen. In [SCML05] konnte dann gezeigt werden, daß CNN ebenfalls in der Lage sind, bivariate Kenngrößen - in diesem Falle ein Maß für Phasen-

synchronisation [MLDE00] - zu schätzen. Außerdem wurden CNN erfolgreich zur Simulation frequenzselektiver nichtlinearer erregbarer Medien eingesetzt, mit denen ebenfalls Synchronisationsmessungen in dynamischen Systemen möglich waren [CMM⁺05, CL07, Gal06].

In der vorliegenden Arbeit wurde untersucht, inwieweit die analytisch gemäß den Gleichungen 2.34 berechneten symmetrischen und asymmetrischen Interdependenzmaße - also Maße für generalisierte Synchronisation - mit CNN approximiert werden können. Eine zuverlässige Approximation dieser Maße mit CNN würde dann nicht nur eine Charakterisierung der Interaktionsstärke zwischen dynamischen Systemen sondern durch die Asymmetrie nichtlinearer Interdependenzmaße auch eine Detektion der Interaktionsrichtung mit CNN ermöglichen. Im folgenden wird die Methodik vorgestellt, die in der vorliegenden Arbeit verwendet wurde, um nichtlineare Interdependenzmaße mit CNN zu approximieren.

4.1 Datenvorverarbeitung

Gegeben seien zwei (mit Abtastintervall Δt) gemessene Zeitreihen $x^{(roh)}(t)$ und $y^{(roh)}(t)$ zweier Systeme X und Y mit jeweils M Datenpunkten:

$$\begin{aligned} x^{(roh)}(n\Delta t), \quad n = 0, \dots, M-1 \\ y^{(roh)}(n\Delta t), \quad n = 0, \dots, M-1 \end{aligned} \tag{4.1}$$

Jede Zeitreihe wird vor der Verarbeitung zunächst Mittelwert-bereinigt:

$$\begin{aligned} x_j^* &= x_j^{(roh)} - \bar{x}^{(roh)} \quad j = 1, \dots, M, \\ y_j^* &= y_j^{(roh)} - \bar{y}^{(roh)} \quad j = 1, \dots, M, \end{aligned} \tag{4.2}$$

wobei $\bar{x}^{(roh)}$ und $\bar{y}^{(roh)}$ den Mittelwert der jeweiligen Zeitreihen bezeichnen.

Anschließend wird, um den gesamten Wertebereich des CNN (siehe Gleichung 3.6) abzudecken, eine lineare Skalierung auf $x_j, y_j \in [-1, 1]$ durchgeführt:

$$\begin{aligned} x_j &= \frac{x_j^*}{\max(|x_{min}^*|, |x_{max}^*|)} \\ y_j &= \frac{y_j^*}{\max(|y_{min}^*|, |y_{max}^*|)}. \end{aligned} \quad (4.3)$$

Wie bereits erwähnt, werden CNN hauptsächlich in der Bildverarbeitung eingesetzt. Daher sind die meisten Hardwarerealisierungen von CNN [LPKH02, LPKH04, RLC⁺04] als quadratisches Gitter von $M = M_x \times M_y$, ($M_x = M_y$) Zellen aufgebaut. Dies wurde für die vorliegende Arbeit als Grundtopologie übernommen. Daraus ergibt sich die Möglichkeit, die aktuellen Werte der Variablen von Zellen des CNN (Eingang, Zustand, Ausgang, und Schwellenwert) jeweils als „Bild“ zu repräsentieren, indem jedes Pixel des Bildes einer Zelle entspricht (siehe Abbildung 4.1).




Abbildung 4.1: Beispiel einer Ausgabe eines 64×64 CNN in Bilddarstellung. Jedes Pixel entspricht einer Zelle des CNN. Der Wert der Ausgabe der Zellen wird in Graustufen kodiert, so daß ein weißes Pixel -1 und ein schwarzes Pixel +1 entspricht.

Da nichtlineare Interdependenzmaße bivariate Kenngrößen sind, müssen die Werte zweier Zeitreihen x_j, y_j (siehe Gleichung 4.3) in das CNN eingelesen werden. In [Sow04] wurden verschiedene Möglichkeiten (zeilenweise, spiralförmig, Zeitreihenwerte abwechselnd) getestet, wobei sich eine zeilenweise Anordnung von links oben nach rechts unten als überlegen herausstellte. Hierbei wurden die Datenpunkte der ersten Zeitreihe x_j jeweils als Eingang G und die der zweiten Zeitreihe y_j als Startzustand $Z(0)$ in die Zellen gespeichert:

$$g_{ij} = x_{jM_x+i}; \quad i = 0, \dots, M_x - 1; \quad j = 0, \dots, M_y - 1 \quad (4.4)$$

$$z_{ij}(0) = y_{jM_x+i}; \quad i = 0, \dots, M_x - 1; \quad j = 0, \dots, M_y - 1 \quad (4.5)$$




Abbildung 4.2: Schematische Darstellung der Datenanordnung im CNN. Die Zahlen in den Zellen geben den Index des Datenpunktes innerhalb einer Zeitreihe an.

Dies führt zwar zu einer Asymmetrie im Einfluss der beiden Zeitreihen auf das Netzwerk, insofern als daß der Eingang G zeitlich konstant ist, während sich der Zustand $Z(t)$ gemäß Gleichung 3.7 verändert. Es sei aber darauf hingewiesen, daß in [Sow04] eine abwechselnde Anordnung von Datenpunkten beider Zeitreihen in entweder Startzustand oder Eingang zu keiner Verbesserung der Ergebnisse führte. Es ist zudem zu beachten, daß dann nur Zeitreihen mit halber Länge bei gleicher Netzgröße analysiert werden können.

In sämtlichen Untersuchungen wurde die geschlossene Spirale als Randbedingung gewählt (siehe Abschnitt 3.4.4). Diese erhält bei zeilenweiser Datenanordnung an den Rändern des Netzes die chronologische Abfolge der eingelesenen Zeitreihen. In vertikaler Richtung wurde ebenfalls eine geschlossene Spirale verwendet (siehe auch Abbildung 4.3). Dies erzeugt Kopplungen zwischen Zellen mit Datenpunkten der Zeitreihe, für die i.a. keine Korrelation zu erwarten ist, was jedoch bei sämtlichen anderen Randbedingungen ebenfalls der Fall gewesen wäre.




Abbildung 4.3: Schematische Darstellung der verwendeten Randbedingungen. Links: Durch die geschlossene Spirale wird die Chronologie der Zeitreihe erhalten. Rechts: Auch in vertikaler Richtung wird eine geschlossene Spirale verwendet.

Darüber hinaus wurde die Eignung dieser Randbedingung für die Approximation von Synchronisationsmaßen in [SCML05, KOEL07] nachgewiesen.

Die gewählten Templates wiesen für alle folgenden Untersuchungen eine 3×3 -Einflussumgebung auf, da dies mit aktuellen hardwaretechnischen Realisationen vereinbar ist [ZRFS03, RLC⁺04]. Darüber hinaus wurden in [Sow04] teilweise sogar schlechtere Ergebnisse mit einer 5×5 Einflussumgebung erzielt, obwohl kleinere Einflussumgebungen eine Untermenge von größeren bilden. Dies liegt jedoch vermutlich an der Tatsache, daß das Optimierungsverfahren zur Bestimmung geeigneter Templates (siehe Abschnitt 3.5) in höherdimensionalen Räumen nicht in der Lage war, ein Minimum zu finden.

Als Templateordnung wurde durchgängig $p = 3$ gewählt (siehe Abschnitt 3.4.5), da eine lineare Separierbarkeit bei den vorliegenden Synchronisationsmessungen nicht vorausgesetzt werden kann und hardwaretechnische Realisationen bis zu Ordnung 3 existieren [LPKH02, LPKH04]. Darüber hinaus wurden in [KOEL07] die besten Ergebnisse ebenfalls mit $p = 3$ erzielt. Höhere Templateordnungen könnten zwar eventuell eine Verbesserung der Methode bewirken, jedoch stehen zur Zeit keine entsprechenden hardwaretechnischen Realisationen zur Verfügung und außerdem würde der Rechenaufwand des Optimierungsverfahrens stark ansteigen.

Im folgenden wird für sämtliche Untersuchungen ein CNN mit einer sigmoidalen Aktivierungsfunktion aus den in Abschnitt 3.4.2 genannten Vorteilen gegenüber

Stufenfunktionen und stückweise linearen Funktionen verwendet.

4.2 Software-CNN

Da während der Dissertation kein funktionsfähiges Hardware-CNN zur Verfügung stand, wurden ausschließlich Simulationen mit Hilfe eines eigens programmierten Software-CNN-Pakets durchgeführt. Die Vorteile einer solchen Simulation eines CNN liegen in der Möglichkeit, verschiedene Hardwareeigenschaften zu simulieren sowie in der hohen Berechnungsgenauigkeit und den nicht vorhandenen fertigungstechnisch bedingten Bauteiltoleranzen. Ein großer Nachteil ist jedoch, daß das Differentialgleichungssystem aus Zustandsgleichungen (siehe Abschnitt 3.4.5) der Zellen des CNN aufgrund seiner Komplexität nicht analytisch gelöst werden kann. Daher muß auf numerische Integrationsverfahren zurückgegriffen werden, wodurch das Paradigma des analogen Prozessors hier nicht aufrecht erhalten werden kann, sondern eine Diskretisierung erfolgt. Zusätzlich ist die numerische Integration der Zustandsgleichungen sehr rechenintensiv, wodurch der Geschwindigkeitsvorteil der neuronalen Netze durch die Simulation zunächst nicht gegeben ist.

Bei der numerischen Integration der CNN-Zustandsgleichungen handelt es sich um ein *Anfangswertproblem*. Dies bedeutet, daß durch Festlegung der Eingänge g_{ij} und Anfangszustände $z_{ij}(t_0)$ das System zu einem Zeitpunkt $t_0 = 0$ vollständig beschrieben ist und ein Zustand zu einem späteren Zeitpunkt nach einer Transientenzeit $t = t_0 + \tau_{trans}$ berechnet werden soll. Die Wahl eines geeigneten Integrationsalgorithmus hängt dabei von Faktoren wie der gewünschten Genauigkeit oder der Berechnungsgeschwindigkeit ab. In der vorliegenden Arbeit wurde zum einen das Eulerverfahren sowie ein Runge-Kutta-Verfahren 4. Ordnung mit adaptiver Schrittweite verwendet (genauere Informationen zu beiden Verfahren sind in [PTVF02]) zu finden.

4.3 Optimierung

Wie in Abschnitt 3.5 beschrieben, ist es bislang nicht möglich, analytisch Templates zu bestimmen, mit denen das CNN die jeweiligen nichtlinearen Interdependenzmaße approximiert. Daher muß auf ein Optimierungsverfahren zurückgegriffen werden. Die Basis einer Optimierung sind die analytisch berechneten Interdependenzmaße für die zur Verfügung stehenden Zeitreihenpaare $X_i = \{x_{j,i}, j = 1, \dots, M\}$ und

$Y_i = \{y_{j,i}, j = 1, \dots, M\}$ der dynamischen Systeme X und Y . Für diese wird das zu approximierende Interdependenzmaß $I_i(X|Y)$ analytisch gemäß Gleichung 2.34 für sämtliche Zeitreihenpaare berechnet. $I(X|Y)$ ist hierbei als Platzhalter für eines der vorgestellten nichtlinearen Interdependenzmaße $S_s^{(k)}(X|Y)$, $S_a^{(k)}(X|Y)$, $H_s^{(k)}(X|Y)$, $H_a^{(k)}(X|Y)$, $N_s^{(k)}(X|Y)$, $N_a^{(k)}(X|Y)$ zu verstehen, da die im folgenden beschriebene Optimierungsprozedur für alle auf identische Weise durchgeführt wurde.

Zunächst muß für die vorliegenden Zeitreihen untersucht werden, welche Werte I_i für diese annimmt. In Analysen von Felddaten wird im allgemeinen nicht der gesamte theoretisch mögliche Wertebereich der nichtlinearen Interdependenzmaße durch die gegebenen Zeitreihen abgedeckt. Somit stehen für eine Optimierung keine Zeitreihenpaare mit $I_i < I_{min}$ bzw. $I_i > I_{max}$ zur Verfügung, wobei I_{min} den kleinsten und I_{max} den größten für alle Zeitreihenpaare analytisch berechneten Wert des Interdependenzmaßes bezeichnet.

Die Zusammenstellung einer Trainingsmenge T (siehe Abschnitt 3.5) kann mit den vorhandenen Daten X_i, Y_i, I_i auf verschiedene Arten erfolgen. Grundlegende Aspekte wie die möglichst breite Verteilung von irrelevanten Eigenschaften der Eingangsdaten X_i, Y_i sowie der Abdeckung aller relevanten Eigenschaften wurden bereits diskutiert. Darüber hinaus ist es aber ebenfalls von Bedeutung, daß es möglich ist, mit den verwendeten Algorithmen in einer akzeptablen Zeit ein Minimum im Fehleraum zu finden. Im konkreten Falle der Optimierung eines CNN ist es zusätzlich notwendig, daß die gesuchten Templates möglichst stabil sind, d.h. die Zellen des CNN spätestens nach dem Integrationsintervall τ_{trans} einen Zustand angenommen haben, der sich nicht weiter ändert. In der vorliegenden Arbeit wurde durchgängig die bereits in [SCML05, KOEL07] bewährte Methode verwendet. Hierbei wurden von den Werten I_{min} bzw. I_{max} ausgehend zwei Intervalle $[I_{min}; I_{min} + \Delta I_{min}]$ bzw. $[I_{max} - \Delta I_{max}; I_{max}]$ definiert, aus denen Elemente für die Trainingsmenge entnommen wurden. Die Größe der Intervalle wurde dabei von der Besetzungsdichte der zur Verfügung stehenden Zeitreihen X_i, Y_i mit entsprechend kleinen/großen Werten von I_i einzelfallabhängig bestimmt. Üblicherweise wurden für eine Trainingsmenge T mit M_{tr} Elementen (siehe Gleichung 3.8) jeweils $\frac{M_{tr}}{2}$ Elemente aus beiden Intervallen gewählt, damit beide Fälle ausgeglichen repräsentiert waren. Für die eine Hälfte der Trainingselemente mit niedrigen Werten I_i (o.B.d.A. gilt für die Indizes innerhalb der Trainingsmenge $n = 1, \dots, \frac{M_{tr}}{2}$) wurde die Referenz auf -1 gesetzt:

$$\begin{aligned} G_n &= X_i \\ Z_n(0) &= Y_i \\ v_n^{(r)} &= -1 \quad \text{für } i \text{ mit } I_i \in [I_{min}; I_{min} + \Delta I_{min}]. \end{aligned} \quad (4.6)$$

Entsprechend wurde die Referenz für Elemente mit hohen Werten I_i (o.B.d.A. $n = \frac{M_{tr}}{2} + 1, \dots, M_{tr}$) die Referenz auf +1 gesetzt:

$$\begin{aligned} G_n &= X_i \\ Z_n(0) &= Y_i \\ v_n^{(r)} &= +1 \quad \text{für } i \text{ mit } I_i \in [I_{max} - \Delta I_{max}; I_{max}]. \end{aligned} \quad (4.7)$$

Die Werte für die Wahl der Referenzen entsprachen dem Minimum bzw. dem Maximum des CNN-Wertebereiches, welcher durch die sigmoidale Aktivierungsfunktion (siehe Abschnitt 3.4.2) definiert und somit vollständig ausgenutzt wurde.

Um eine Überoptimierung eines CNN zu erkennen, ohne einen Validierungsdatensatz mit einer großen Anzahl Elementen berechnen zu müssen (siehe Abschnitt 3.5.3), kann ggfs. eine Testmenge definiert werden. Diese wird auf die gleiche Weise wie die Trainingsmenge zusammengestellt. Die Testmenge enthält dabei nicht die Zeitreihen, welche bereits für die Trainingsmenge verwendet wurden. Dadurch stellt der globale Fehler $F^{(g, test)}$ einen Schätzer dar, der einen Anhaltspunkt für eine eventuelle Überoptimierung des CNN liefern kann (siehe auch Abschnitt 3.5.2).

4.3.1 Evolutionäres Minimierungsverfahren

Evolutionäre Minimierungsalgorithmen sind durch die biologische Evolution von Lebewesen inspiriert und passen *Individuen* durch *Mutation*, *Selektion* und *Immigration* Generation für Generation immer besser an ihre Umgebung an. Im vorliegenden Fall wird dieses Konzept ausgenutzt, um CNN zu finden, die die gestellte Aufgabe wie gewünscht lösen. Konkret werden CNN mit Kopplungsgewichten a , b und einem Schwellenwert s gesucht, deren Ausgabe für die Elemente der Trainingsmenge den jeweiligen Referenzen $V^{(r)}$ entspricht. Ein Individuum ist dann ein CNN mit einem Satz von Koeffizienten, sprich einem Template. Der Grad der Anpassung wird dann durch den globalen Fehler $F^{(g)}$ (siehe Gleichung 3.10) quantifiziert, welcher den Abstand zwischen tatsächlichen CNN-Ausgaben und den gewünschten Referenzen für alle Elemente der Trainingsmenge bestimmt. Durch Mutation, was im vorliegenden Fall dem zufälligen Verändern der Templateinträge entspricht, werden dann im Laufe des evolutionären Minimierungsverfahrens CNN gefunden, die immer kleinere globale Fehler $F^{(g)}$ aufweisen.




Abbildung 4.4: Ablauf eines evolutionären Minimierungsalgorithmus. Schritt 1: Start mit zufällig generierten Templates. Schritt 2: Die Templates mit dem kleinsten Fehler werden unverändert in die nächste Generation übernommen (Selektion). Schritt 3: Die besten Templates werden verwechselt (Mutation) und ebenfalls zur nächsten Generation hinzugefügt. Dazu kommen völlig neue, mit Zufallszahlen generierte, Templates (Immigration). Schritt 4: Auf die neue Generation werden wieder Selektion, Mutation und Immigration angewendet. Es erfolgt ein Abbruch nach M_e Evolutionsschritten.

Die Eignung evolutionärer Minimierungsverfahren für die Optimierung von CNN wurde bereits in [KR00] gezeigt. Ausgangspunkt ist eine Startgeneration mit M_i Individuen, also M_i zufällig erzeugten Templates, für die jeweils die CNN-Ausgabe und der dazugehörige globale Fehler $F^{(g)}$ berechnet werden. Die Werte für Kopplungsgewichte bzw. den Schwellenwert werden dabei durch gaussverteilte mittelwertfreie Zufallszahlen mit $\sigma = 0,2$ erzeugt [Ame98]. Durch die *Selektion* werden die M_u besten Individuen, also die CNN mit den jeweils kleinsten globalen Fehlern $F^{(g)}$ unverändert in die nächste Generation übernommen. Zusätzlich werden veränderte CNN durch *Mutation* erzeugt, indem auf die Kopplungsgewichte bzw. den Schwellenwert der besten Individuen gleichverteilte Zufallszahlen mit verschiedenen Amplituden addiert werden¹. Somit werden CNN mit Templates getestet, welche im Parameterraum in der Nähe der bisher besten liegen und somit möglicherweise eine noch bessere Fehlerbewertung erhalten. Komplettiert wird die Population der nächsten Generation durch M_n völlig neu erzeugte zufällige CNN,

¹Da die Ausdehnung des Bereiches um ein Minimum a priori nicht bekannt ist, werden für jeweils ein Drittel der Individuen gleichverteilte Zufallszahlen aus den Intervallen $[-1; 1]$, $[-0,5; 0,5]$ sowie $[-0,3; 0,3]$ auf die Kopplungsgewichte und den Schwellenwert addiert.

welche *Immigranten* genannt werden, um zusätzlich neue Bereiche des Parameterraums zu erschließen. Die Templates werden dabei wieder durch gaussverteilte mittelwertfreie Zufallszahlen mit $\sigma = 0,2$ erzeugt [Ame98]. Für die CNN dieser neuen Population wird nun der nächste Evolutionsschritt durchgeführt, d.h. wieder die globalen Fehler berechnet und Selektion, Mutation und Immigration angewendet (siehe auch Abbildung 4.4). Die Parallelisierung dieses Verfahrens erfolgte in der vorliegenden Arbeit dadurch, daß auf jedem Clientrechner M_s autonome Evolutionsschritte durchgeführt wurden, bevor eine Rückmeldung der Ergebnispopulation zu einem Server stattfand und dort mit den Populationen der anderen Clientrechner verglichen wurde (dies wird im folgenden als *Trainingsschritt* bezeichnet). Auf Basis einer neu zusammengesetzten Population aus den bisher besten Individuen aller Rechner wurden erneut M_s autonome Evolutionsschritte auf jedem Rechner durchgeführt. Mit M_g Trainingsschritten werden dann insgesamt $M_e = M_g M_s$ Evolutionsschritte berechnet. Auf diese Weise wird der Parameterraum kollektiv nach Minima durchsucht, wobei aber langsame Clients im heterogenen Computernetzwerk den Algorithmus nicht bremsen.

4.4 Validierung

Die Out-Of-Sample Validierung von optimierten CNN wurde mit einer großen Anzahl von Zeitreihen durchgeführt, um eine statistisch zuverlässige Aussage zu erhalten. Dabei wurden innerhalb der Validierungsmenge $T^{(val)}$ Zeitreihen, welche zuvor in Trainings- bzw. Testmenge enthalten waren, nicht berücksichtigt.

Nach Integration der Zustandsgleichungen der Zellen des CNN bis zum Zeitpunkt τ_{trans} wird die Verarbeitung gestoppt (siehe Abschnitt 3.4) und der Zustand des Netzes als Endzustand definiert. Um aus diesem Endzustand das approximierte Interdependenzmaß zu erhalten, wird zunächst der Mittelwert aller Zellausgänge berechnet:

$$K = \frac{1}{M_x M_y} \sum_{i=1}^{M_x} \sum_{j=1}^{M_y} v_{ij}(\tau_{trans}). \quad (4.8)$$

Dadurch, daß das Netz auf Werte des Interdependenzmaßes von $[I_{min}, I_{max}]$ trainiert wurde (siehe Abschnitt 4.3), muß eine Reskalierung auf diesen Wertebereich erfolgen, um das approximierte Interdependenzmaß zu erhalten:

$$I^{(\text{CNN})} = (K + 1) \frac{I_{\max} - I_{\min}}{2} + I_{\min} \quad (4.9)$$

Die Güte eines CNN wird durch die mittlere Abweichung zwischen analytisch berechnetem Interdependenzmaß I und approximierter Kenngröße $I^{(\text{CNN})}$ für die M_{val} Elemente der Validierungsmenge bestimmt:

$$F^{(\text{val})} = \frac{1}{M_{\text{val}}(I_{\max} - I_{\min})} \sum_{n=1}^{M_{\text{val}}} \left| I_i - I_i^{(\text{CNN})} \right|. \quad (4.10)$$

Durch den Faktor $I_{\max} - I_{\min}$ im Nenner wird $F^{(\text{val})}$ auf den Wertebereich $[I_{\min}, I_{\max}]$ normiert und nicht auf den theoretisch möglichen des jeweiligen Interdependenzmaßes. Dies war notwendig, da durch die Skalierung in Gleichung 4.9 die Abweichung $\left| I_i - I_i^{(\text{CNN})} \right|$ auf $[I_{\min}, I_{\max}]$ eingeschränkt ist. Folglich wäre ohne den Faktor $I_{\max} - I_{\min}$ in Gleichung 4.10 die Vergleichbarkeit der Güte $F^{(\text{val})}$ verschiedener Approximationen nicht gegeben.

5 Analyse von synthetischen Zeitreihen

In diesem Kapitel wird die Eignung des vorgestellten Verfahrens zur Approximation von nichtlinearen Interdependenzmaßen mit CNN anhand synthetischer Zeitreihen von Modellsystemen überprüft. Dazu wurden Oszillatoren mit chaotischer Dynamik untersucht, deren Eigenschaften wohlbekannt sind und über verschiedene Parameter kontrolliert werden können (siehe auch Anhang A). Damit boten sie eine ideale Grundlage, die Möglichkeiten und Grenzen des Verfahrens zu studieren. Zunächst wurde untersucht, ob Interdependenzmaße - analytisch berechnet für Zeitreihen strukturell ähnlicher Modellsysteme - mit CNN approximiert werden konnten. Diese Systeme besaßen identische Bewegungsgleichungen, jedoch im hier untersuchten Fall unterschiedliche Eigenfrequenzen. Mit Hilfe eines Kontrollparameters konnte die Interaktionsstärke zwischen den Systemen variiert werden, wodurch sich verschiedene Synchronisationsregime erzeugen ließen (unabhängige Systeme, schwach wechselwirkende Systeme und synchronisierte Systeme, siehe auch Abschnitt 2.6). Es wurde untersucht, ob CNN in der Lage waren, diese Regimes im Hinblick auf die Stärke der Synchronisation (symmetrisches Interdependenzmaß) zu unterscheiden und somit die Interaktionsstärke zu schätzen. Zudem wurde überprüft, ob CNN die Interaktionsrichtung zwischen den dynamischen Systemen detektieren konnten (asymmetrisches Interdependenzmaß). Da bei der Analyse von Felddaten nicht davon ausgegangen werden kann, daß die untersuchten Systeme ähnliche Dynamiken aufweisen, wurden die gleichen Untersuchungen auf strukturell unterschiedliche Modellsysteme erweitert. Diese zeichneten sich durch verschiedene Bewegungsgleichungen und somit unterschiedliche Dynamiken aus. Die Ergebnisse aller genannten Untersuchungen wurden in [KOEL07] publiziert.

5.1 Strukturell ähnliche Systeme

5.1.1 Symmetrisches Interdependenzmaß

Für die Untersuchung strukturell ähnlicher Systeme wurden Zeitreihen von zwei Rössleroszillatoren X und Y mit unterschiedlichen Eigenfrequenzen $\omega_X = 0,89$ und $\omega_Y = 0,85$ verwendet (siehe Anhang A.3). Die beiden Oszillatoren wurden bidirektional über einen Parameter $\epsilon = \epsilon_{XY} = \epsilon_{YX}$ gekoppelt. Dieser wurde in 41 Schritten zwischen $0 < \epsilon < 0,04$ variiert, so daß der Bereich zwischen ungekoppelten und synchronisierten Systemen abgedeckt wurde.

Die Integration der Differentialgleichungen der Modellsysteme erfolgte mit Hilfe eines Runge-Kutta Verfahrens 4. Ordnung in 5096 Schritten mit jeweils einer Länge von $h = 0,1$. Die ersten 1000 Integrationsschritte wurden als Transiente verworfen, so daß jeweils Zeitreihen mit $M = 4096$ Datenpunkten erzeugt wurden. Zu jeder Kopplungsstärke ϵ wurden 20 Systemrealisationen der Modellzeitreihen erzeugt, d.h. jeweils 20 Zeitreihen mit zufällig im Zustandsraum gewählten Anfangsbedingungen¹. Von den beiden Modellsystemen wurde jeweils die erste Komponente der Bewegungsgleichungen zur weiteren Verarbeitung verwendet², womit 820 Paare von Zeitreihen zur Verfügung standen.

Für die Paare von Zeitreihen wurde jeweils das nichtlineare Interdependenzmaß $N_s^{(k)}(X|Y)$ mit $k = 6$ [Ost08] und einer Theilerkorrektur von $\Lambda = 20$ Datenpunkten analytisch gemäß Gleichung 2.34 berechnet³. Die Zeitreihen wurden dazu zunächst in einen Zustandsraum der Dimension $m = 7$ [SYC91] mit einem Versatz von $\tau = 14$ [ABST93] Datenpunkten eingebettet (siehe auch Tabelle 5.1).

Anzahl nächste Nachbarn	$k = 6$
Einbettungsdimension	$m = 7$
Zeitversatz	$\tau = 14$ Datenpunkte
Theilerkorrektur	$\Lambda = 20$ Datenpunkte

Tabelle 5.1: Übersicht der Parameter, mit denen das nichtlineare Interdependenzmaß $N_s^{(k)}(X|Y)$ berechnet wurde.

¹Die Anfangsbedingungen lagen im Zustandsraum jeweils in der Nähe des Attraktors, damit die Trajektorien auf diesen zuliefen und nicht divergierten.

²Die Meßfunktion ψ (siehe Gleichung 2.9) war in diesem Falle die Identität der ersten Komponente der Systeme.

³Im folgenden wurde aufgrund der Übersichtlichkeit die abgekürzte Schreibweise N_s verwendet.

Die Trainingsmenge T wurde aus $M_{tr} = 10$ Elementen zusammengestellt. Dazu wurden 5 Elemente mit niedrigen Werten $N_s \in [-0,08; 0,08]$ und 5 Elemente mit hohen Werten $N_s \in [0,83; 0,97]$ gewählt (siehe auch Gleichungen 4.6 bzw. 4.7). Die Integration des CNN erfolgte mit Hilfe des Eulerverfahrens mit einem Integrationsintervall von $\tau_{trans} = 20$ in 100 Schritten. Der evolutionäre Minimierungsalgorithmus wurde mit den in Tabelle 5.2 aufgezeigten Parametern ausgeführt (siehe auch Abschnitt 4.3.1). Bereits nach $M_g = 61$ Trainingsschritten (entspricht 1220 Evolutionsschritten) wurde ein CNN mit einem globalen Fehler von $F^{(g)} = 3,374 \cdot 10^{-3}$ erhalten, welches sich im weiteren Verlauf der Optimierung bis 1500 Trainingsschritte nicht mehr verbessern ließ. Dieses CNN wurde für die anschließende Out-Of-Sample Validierung verwendet (Template siehe Anhang B).

Evolutionsschritte pro Trainingsschritt	$M_s = 20$
Trainingsschritte	$M_g = 1500$
Evolutionsschritte insgesamt	$M_g M_s = 30000$
Populationsgröße	$M_i = 50$
Überlebende pro Evolutionsschritt	$M_u = 10$
Mutierte Individuen pro Evolutionsschritt	$M_m = 30$
Immigranten pro Evolutionsschritt	$M_n = 30$

Tabelle 5.2: Parameter des evolutionären Minimierungsverfahrens.

Die Validierung erfolgte für die $M_{val} = 810$ Paare von Zeitreihen, die nicht Element der Trainingsmenge waren. In Abbildung 5.1 sind die Mittelwerte von analytischem und approximiertem Maß für die jeweils 20 Realisationen gegen die Kopplungsstärke ϵ aufgetragen. Es ist zu erkennen, daß sowohl das analytisch berechnete nichtlineare Interdependenzmaß als auch die CNN-basierte Approximation die theoretisch erwartete Abhängigkeit von der Kopplungsstärke zeigten (siehe Abschnitt 2.6). Wie in Abschnitt 2.5.3 beschrieben, nahm N_s für nicht oder nur sehr schwach gekoppelte Systeme negative Werte an. Es wird deutlich, daß mit Hilfe der CNN-basierten Approximation $N_s^{(CNN)}$ die Regime ohne bzw. mit nur schwacher Kopplung, das intermittente Regime sowie das Regime mit synchronisierten Systemen differenziert werden konnten. Die Abweichung der Approximation für die Elemente der Validierungsmenge betrug $F^{(val)} = 12\%$. Es war zu beobachten, daß etwa im Bereich zwischen $0,2 < \epsilon < 0,3$ der Anstieg von N_s etwas verzögert vom CNN reproduziert wurde. Die durchgängig etwas höhere Standardabweichung der CNN-basierten Approximation war durch die Tendenz der Zellen zu stabilen Ausgabewerten $v(\tau_{trans}) \rightarrow \pm 1$ aufgrund der sigmoidalen Aktivierungsfunktion zu erklären.




Abbildung 5.1: Mittelwerte und Standardabweichungen des analytisch berechneten symmetrischen Interdependenzmaßes (schwarz) und CNN-basierter Approximation (rot) für jeweils 20 Systemrealisationen in Abhängigkeit der Kopplungsstärke ϵ .

Das CNN war also nach einer Optimierung mit lediglich 10 Beispielzeitreihen in der Lage, die Interaktionsstärke zwischen zwei dynamischen Systemen anhand ihrer Zeitreihen mit hoher Zuverlässigkeit zu schätzen.

5.1.2 Asymmetrisches Interdependenzmaß

Für die Approximation des asymmetrischen Interdependenzmaßes $N_a^{(k)}(X|Y)$ wurden die gleichen Rössleroszillatoren wie zuvor verwendet, wobei die Kopplung von System Y nach System X zu $\epsilon_{YX} = 0$ gewählt wurde. Die unidirektionale Kopplung $\epsilon = \epsilon_{XY}$ wurde in 41 Schritten zwischen $0 < \epsilon < 0,2$ variiert.

Die Integration der Differentialgleichungen der Rösslersysteme erfolgte nach dem gleichen Schema wie in Abschnitt 5.1.1. Es wurden wieder 20 Systemrealisationen pro Kopplungsstärke, d.h. 820 Paare (jeweils wieder die ersten Komponenten der Bewegungsgleichungen der Systeme) von Zeitreihen erzeugt. Die Berechnung des asymmetrischen Interdependenzmaßes $N_a^{(k)}(X|Y)$ erfolgte mit den identischen Parametern wie für das symmetrische Maß⁴ (siehe Tabelle 5.1).

⁴Im folgenden wurde die abgekürzte Schreibweise N_a verwendet.

Die Trainingsmenge T wurde wieder aus $M_{tr} = 10$ Elementen zusammengestellt. Dazu wurden 5 Elemente mit niedrigen Werten $N_a \in [-0, 1; 0]$ und 5 Elemente mit hohen Werten $N_a \in [0, 31; 0, 35]$ gewählt. Die Integration des CNN erfolgte mit Hilfe des Eulerverfahrens mit einem Integrationsintervall von $\tau_{trans} = 20$ in 100 Schritten. Das evolutionäre Minimierungsverfahren wurde mit den identischen Parametern wie beim symmetrischen Interdependenzmaß durchgeführt (siehe Tabelle 5.2). Die Optimierung ergab ein CNN mit einem globalen Fehler von $F^{(g)} = 0,082$ (Template siehe Anhang B).




Abbildung 5.2: Mittelwerte und Standardabweichungen des analytisch berechneten asymmetrischen Interdependenzmaßes (schwarz) und CNN-basierter Approximation (rot) für jeweils 20 Systemrealisationen in Abhängigkeit der Kopplungsstärke ϵ .

Die Ergebnisse der Validierung für die 810 Zeitreihenpaare, die nicht Elemente der Trainingsmenge waren, sind in Abbildung 5.2 gezeigt. Es ist zu erkennen, daß auch für das asymmetrische nichtlineare Interdependenzmaß die theoretisch zu erwartende Abhängigkeit von der Kopplungsstärke (siehe Abschnitt 2.6) erhalten wurde. Hierbei wurde System X korrekt als Treiber identifiziert. Der qualitativ gleiche Verlauf konnte mit dem CNN sehr gut reproduziert werden. Die Abweichung der Approximation für die Elemente der Validierungsmenge belief sich auf $F^{(val)} = 17\%$. Die CNN-basierte Approximation $N_a^{(CNN)}$ zeigte dabei im Kopplungsstärkebereich $0,02 < \epsilon < 0,12$ ebenso wie das analytisch berechnete N_a die Interaktionsrichtung korrekt an. Auffällig war allerdings, daß die CNN-basierte Approximation für schwach gekoppelte und synchronisierte Systeme Werte $N_a^{(CNN)} > 0$ annahm. Dies war dadurch zu erklären, daß das hier optimierte CNN aufgrund seines Templates

nicht in der Lage war, ein vollständig weißes Ausgabebild zu erzeugen, also Werte der Ausgänge von $v = -1$ für alle Zellen. Dennoch konnte mit dem CNN die Interaktionsrichtung zwischen den betrachteten dynamischen Systemen anhand ihrer Zeitreihen zuverlässig detektiert werden.

5.2 Strukturell unterschiedliche Systeme

5.2.1 Symmetrisches Interdependenzmaß

In diesem Abschnitt wird das Verfahren zur Approximation von Interdependenzmaßen mit CNN auf interagierende dynamische Systeme mit unterschiedlicher Dynamik angewendet. Dazu wurde ein Rössleroszillator X als Treiber unidirektional in ein Lorenzsystem Y eingekoppelt (siehe Anhang A.5). Da das Lorenzsystem eine höhere Eigenfrequenz aufwies als die in den vorigen Abschnitten verwendeten Rössleroszillatoren, wurden die Bewegungsgleichungen der Systeme mit einer kleineren Schrittweite von $h = 0,01$ integriert. Entsprechend wurden die ersten 10000 Integrationsschritte als Transiente verworfen. Außerdem wurden aufgrund der höheren Abtastrate $M = 16384$ Datenpunkte verwendet, um die Dynamik beider Systeme über einen ausreichend langen Zeitraum zu erfassen. Dies entsprach einem 128×128 Zellen großen CNN [RLC⁺04].

Die unidirektionale Kopplungsstärke $\epsilon = \epsilon_{XY}$ wurde in 45 Schritten zwischen $[0, 6; 2, 4]$ variiert. Je Kopplungsstärke wurden 20 Systemrealisationen, d.h. 900 Paare von Zeitreihen, erzeugt. Dabei wurden von beiden Systemen jeweils die ersten Komponenten der Bewegungsgleichungen für die weiteren Untersuchungen verwendet.

Anzahl nächste Nachbarn	$k = 6$
Einbettungsdimension	$m = 5$
Zeitversatz	$\tau = 1$ Datenpunkt
Theilerkorrektur	$\Lambda = 10$ Datenpunkte

Tabelle 5.3: Übersicht der Parameter, mit denen das nichtlineare Interdependenzmaß $N_s^{(k)}(X|Y)$ berechnet wurde.

Bei der analytischen Berechnung des Interdependenzmaßes $N_s^{(k)}(X|Y)$ für diese Zeitreihenpaare wurde eine Einbettungsdimension von $m = 5$ gewählt [QAG00].

Die Zeitverzögerung betrug $\tau = 1$ Datenpunkt⁵ (siehe auch Tabelle 5.3). Hierzu ist anzumerken, daß die Dekorrelationszeit der Systeme im vorliegenden Fall nicht eindeutig bestimmt werden konnte, da der Lorenzoszillator mit zunehmender Kopplungsstärke die langsamere Dynamik des treibenden Rösslerszillators annahm. Somit müsste eine Anpassung von τ je Kopplungsstärke erfolgen und würde somit eine zusätzliche Parameterabhängigkeit bedeuten, worauf hier verzichtet wurde.

Die Trainingsmenge T wurde wieder aus $M_{tr} = 10$ Elementen zusammengestellt. Dazu wurden 5 Elemente mit niedrigen Werten $N_s \in [-0,02; 0,02]$ und 5 Elemente mit hohen Werten $N_s \in [0,63; 0,67]$ gewählt. Die Integration des CNN erfolgte mit Hilfe des Eulerverfahrens mit einem Integrationsintervall von $\tau_{trans} = 20$ in 100 Schritten. Das evolutionäre Minimierungsverfahren wurde mit den Tabelle 5.2 gezeigten Parametern durchgeführt. Bereits nach 11 Trainingsschritten ergab sich ein CNN mit einem globalen Fehler von $F^{(g)} \approx 0$, welches dementsprechend mit den Zeitreihen der Trainingsmenge perfekt arbeitete (Template siehe Anhang B).

Die anschließende Validierung mit den 890 Zeitreihenpaaren, die nicht Elemente der Trainingsmenge waren, ergab eine Abweichung von $F^{(val)} = 14\%$ (siehe auch Abbildung 5.3). Hierbei konnte wiederum die theoretisch zu erwartende Abhängigkeit des analytisch berechneten Interdependenzmaßes von der Kopplungsstärke (siehe Abschnitt 2.6) beobachtet werden. Das CNN war in der Lage, diese Abhängigkeit mit hoher Güte zu reproduzieren. Auffällig war die erhöhte Standardabweichung im Kopplungsbereich von etwa $0,8 < \epsilon < 1,2$. Dies trat aufgrund von Intermittenzefekten auf, bei denen die Oszillatoren stark abhängig von den Anfangsbedingungen abschnittsweise synchronisiert sind. Es ist zu erkennen, daß die CNN-basierte Approximation dennoch in der Lage war, die ansteigende Kopplungsstärke im Mittel zu detektieren. Somit war es auch für strukturell unterschiedliche Systeme mit unterschiedlichen Dynamiken möglich, ein CNN zu finden, welches die Interaktionsstärke zwischen diesen anhand ihrer Zeitreihen zuverlässig schätzen konnte.

5.2.2 Asymmetrisches Interdependenzmaß

Für die Approximation des asymmetrischen Interdependenzmaßes $N_a^{(k)}(X|Y)$ für strukturell unterschiedliche Systeme wurden die gleichen Modellsysteme und Zeitreihen wie für das symmetrische Maß verwendet (siehe Abschnitt 5.2.1). Das asymmetrische Interdependenzmaß $N_a^{(k)}(X|Y)$ wurde mit den in Tabelle 5.3 aufge-

⁵Im folgenden wurde die abgekürzte Schreibweise N_s verwendet.




Abbildung 5.3: Mittelwerte und Standardabweichungen des analytisch berechneten symmetrischen Interdependenzmaßes (schwarz) und CNN-basierter Approximation (rot) für jeweils 20 Systemrealisationen in Abhängigkeit der Kopplungsstärke ϵ .

listeten Parametern berechnet⁶.

Die Trainingsmenge T wurde wieder aus $M_{tr} = 10$ Elementen zusammengestellt. Dazu wurden 5 Elemente mit niedrigen Werten $N_a \in [-0, 11; -0, 09]$ und 5 Elemente mit hohen Werten $N_a \in [0, 2; 0, 5]$ gewählt. Die Integration des CNN erfolgte mit Hilfe des Eulerverfahrens mit einem Integrationsintervall von $\tau_{trans} = 20$ in 100 Schritten. Das evolutionäre Minimierungsverfahren wurde mit den Tabelle 5.2 gezeigten Parametern durchgeführt. Die Optimierung ergab ein CNN mit einer Bewertung des globalen Fehlers von $F^{(g)} = 0,137$ (Template siehe Anhang B).

Die Validierung dieses CNN mit den 890 Zeitreihenpaaren, die nicht in der Trainingsmenge verwendet wurden, ergab eine Abweichung der CNN-basierten Approximation von $F^{(val)} = 10\%$. In Abbildung 5.4 ist zu erkennen, daß die theoretisch erwartete Abhängigkeit des analytisch berechneten Interdependenzmaßes von der Kopplungsstärke auch für die Zeitreihen strukturell unterschiedlicher dynamischer Systeme erhalten wurde. Hierbei konnte die Kopplungsrichtung im Bereich $0,8 < \epsilon < 1,2$ korrekt detektiert werden, obwohl durch Intermittenzeffekte verursachte größere Standardabweichungen beim analytisch berechneten Interdependenzmaß auftraten. Das CNN war dennoch in der Lage, das asymmetrische Interdependenzmaß mit hoher Güte zu reproduzieren. Somit war es auch für strukturell

⁶Im folgenden wurde die abgekürzte Schreibweise N_a verwendet.

unterschiedliche Systeme mit unterschiedlichen Dynamiken möglich, die Interaktionsrichtung zwischen diesen anhand ihrer Zeitreihen mit CNN zu detektieren.




Abbildung 5.4: Mittelwerte und Standardabweichungen des analytisch berechneten asymmetrischen Interdependenzmaßes (schwarz) und CNN-basierter Approximation (rot) für jeweils 20 Systemrealisationen in Abhängigkeit der Kopplungsstärke ϵ .

5.3 Diskussion

Die Untersuchungen an synthetischen Zeitreihen ergaben, daß die Approximation des symmetrischen und asymmetrischen nichtlinearen Interdependenzmaßes $N_s^{(k)}(X|Y)$ bzw. $N_a^{(k)}(X|Y)$ mit CNN mit einer hohen Güte möglich ist. Im Falle der Schätzung der Interaktionsstärke zwischen strukturell ähnlichen dynamischen Systemen konnten somit die Ergebnisse aus [Kru06] bestätigt werden. Dort gelang es jedoch nicht, die Dynamik strukturell unterschiedlicher dynamischer Systeme mit CNN zuverlässig zu analysieren, da mit dem dort verwendeten Optimierungsverfahren kein geeignetes CNN bestimmt werden konnte. Erst durch das in Abschnitt 4.3 vorgestellte Optimierungsverfahren auf Basis eines evolutionären Minimierungsalgorithmus war es hier möglich, ein CNN zu finden, welches mit hoher Zuverlässigkeit die Interaktionsstärke auch anhand von Zeitreihen von Systemen mit unterschiedlichen Dynamiken schätzen konnte.

Darüber hinaus konnte hier erstmals nachgewiesen werden, daß CNN geeignet sind,

die Interaktionsrichtung zwischen dynamischen Systemen anhand an ihnen gemessener Zeitreihen zu detektieren. Dabei konnte sowohl für Systeme mit ähnlicher als auch unterschiedlicher Dynamik jeweils das treibende System im Mittel korrekt identifiziert werden. Die Eignung von CNN zur Detektion einer Interaktionsrichtung zwischen strukturell ähnlichen dynamischen Systemen konnte in [Glü09] auf Basis eines informationstheoretischen Ansatzes sowie eines Phasen-basierten Ansatzes jeweils bestätigt werden. In [Dic10] wurden darüber hinaus Hinweise gefunden, daß durch eine Erweiterung von CNN um Zellkopplungen mit komplexen Topologien (beispielsweise langreichweitige oder zufällige Kopplungen) eine effektivere Optimierung möglich sein könnte.

6 Analyse von Zeitreihen hirnelektrischer Aktivität

In diesem Kapitel soll die Eignung von CNN zur Messung der Interaktionsstärke bzw. Interaktionsrichtung zwischen Hirnstrukturen anhand von Zeitreihen hirnelektrischer Aktivität überprüft werden. Dazu wurde das im vorigen Kapitel erfolgreich an Zeitreihen von Modellsystemen untersuchte Konzept zur Approximation von nichtlinearen Interdependenzmaßen auf elektroenzephalographische Aufzeichnungen von Epilepsiepatienten angewendet. In Voruntersuchungen wurde dazu zunächst das in Abschnitt 4.3 vorgestellte Optimierungsverfahren dahingehend näher untersucht, ob sich eine Überoptimierung der CNN durch Einführung einer Testmenge noch effektiver vermeiden ließ. Anschließend wurden CNN für die Approximation eines symmetrischen sowie eines asymmetrischen nichtlinearen Interdependenzmaßes anhand von Zeitreihen verschiedener Hirnstrukturen einzelner Patienten optimiert. Hier wurde überprüft, ob CNN in der Lage sind, die Interaktionsstärke bzw. Interaktionsrichtung zwischen verschiedenen Hirnstrukturen zuverlässig zu schätzen. Die hierbei gefundenen CNN wurden dann jeweils auf ihre Generalisierungseigenschaften hin untersucht, inwieweit die Interaktionsstärke bzw. Interaktionsrichtung zwischen Hirnstrukturen, deren Zeitreihen nicht zur Optimierung genutzt wurden, korrekt geschätzt werden konnte. Anschließend wurde untersucht, ob sich diese Generalisierungseigenschaften durch Optimierungen mit Zeitreihen verschiedener Hirnstrukturen oder verschiedener Patienten verbessern ließen und ob somit universell einsetzbare CNN gefunden werden konnten. Abschließend wurde die Eignung der CNN zur Detektion prädiktiver Strukturen in Zeitreihen, d.h. Merkmalen, die zur Vorhersage epileptischer Anfälle genutzt werden könnten, untersucht.

6.1 Epilepsie, Elektroenzephalogramm

Epilepsie ist eine Erkrankung des zentralen Nervensystems, die charakterisiert ist durch wiederkehrende Krampfanfälle - auch epileptische Anfälle genannt [EP07].

Ein epileptischer Anfall entspricht einem pathologisch synchronen und rhythmischen Feuern großer Neuronenverbände, welches typischerweise für eine Zeitspanne von mehreren Sekunden bis einigen Minuten anhält¹.

Ursachen, Typen und Symptome von Epilepsien sind sehr vielfältig. Grob lassen sich jedoch zunächst die Anfälle in *primär generalisierte* Krampfanfälle und *fokale* Krampfanfälle unterscheiden². Primär generalisierte Krampfanfälle sind dadurch charakterisiert, daß keine eng begrenzte Gehirnregion als Anfallsherd identifiziert werden kann und sich der Anfall dementsprechend in großen Teilen des Gehirns mehr oder weniger gleichzeitig manifestiert. Bei einem fokalen Krampfanfall hingegen existiert eine eng umschriebene Hirnregion - der *epileptische Fokus* - in der Anfallsaktivität initial auftritt und sich von dort auf große Teile des Gehirns ausbreiten kann [RL01, KLM⁺06]. Untersuchungen der letzten Jahre deuten darauf hin, daß es sich in beiden Fällen um ein Netzwerkphänomen handelt, weshalb in diesem Zusammenhang auch von einem *epileptischen Netzwerk* gesprochen wird [BZM⁺98, BWE00, BWB⁺01, ADL⁺02, Spe02, GRT⁺06, BCW08, Got08, LC08].

Ungefähr 1% der Weltbevölkerung leidet an einer Form von Epilepsie [DSSW06, Gue06]. Etwa zwei Drittel der Patienten sind medikamentös behandelbar [KB06], so daß zumindest eine signifikante Verminderung der Anfallshäufigkeit erzielt werden kann. Bei ca. 10% der Patienten ist es möglich, durch einen neurochirurgischen Eingriff, bei dem der epileptische Fokus entfernt wird, eine signifikante Besserung zu erreichen [Dun07]. Dem verbleibenden Viertel der Epilepsiepatienten kann mit aktuell verfügbaren Therapien nicht geholfen werden.

In der Klinik für Epileptologie des Universitätsklinikums Bonn erfolgt eine umfangreiche prächirurgische Diagnostik. Hierbei soll im Falle einer Epilepsie mit fokalen Krampfanfällen abgeklärt werden, wo sich der epileptische Fokus im Gehirn befindet, ob dieser reseziert werden kann und welche Funktionalität umliegende Hirnareale besitzen, um wesentliche Funktionsstörungen des Gehirns aufgrund einer eventuell durchgeführten Operation ausschließen zu können. Hierbei stellt das Elektroenzephalogramm das wichtigste Instrument dar. Bei einem Elektroenzephalogramm (EEG), welches am menschlichen Gehirn 1929 zum ersten Mal abgeleitet wurde [Ber29], wird die zeitliche Veränderung von elektrischen Potentialen, welche mit physiologischen Vorgängen von Neuronenverbänden zusammenhängt [Zsc02, NL05], zwischen Elektroden gemessen.

Ein EEG, welches mit einer auf den Kopf aufgesetzten EEG-Haube aufgezeichnet

¹Anfälle, die über einen noch längeren Zeitraum anhalten, werden als *status epilepticus* bezeichnet.

²In der Literatur wird häufig auch eine Aura - wenn sie isoliert auftritt - als eigenständiger Anfallstyp behandelt.

wurde, bietet Ortsauflösungen im Bereich mehrerer Zentimeter. Da bei einer Resektion möglichst wenig gesundes Gehirngewebe entfernt werden soll, ist dies jedoch zu ungenau. Zudem wirken die verschiedenen Gewebearten wie Haut, Schädelknochen und Hirnflüssigkeit durch unterschiedliche Impedanzen als Tiefpaßfilter. Um diese Effekte zu verringern, werden für eine Messung des sog. Elektrokortikogramms (ECoG) Streifen- oder Gitterelektroden neurochirurgisch subdural auf den Cortex aufgelegt. Bei Temporallappenepilepsien, bei denen der epileptische Fokus tief im Gehirnnieren liegt, wird unter Umständen ein Stereo-Elektroenzephalogramm (SEEG) an meist bilateral implantierten, intrahippokampal gelegenen, Stabelektroden aufgezeichnet. Ein Grund hierfür ist, daß die abgetasteten Hirnstrukturen aufgrund der Neuronenanordnung ein elektrisch abgeschlossenes Feld produzieren. SEEG und ECoG zeichnen sich durch eine räumliche Auflösung unter 1 cm sowie durch ein hohes Signal-zu-Rausch Verhältnis aus und weisen vergleichsweise wenig Bewegungsartefakte auf.




Abbildung 6.1: Ausschnitt eines SEEG während eines einsetzenden Anfalls an 20 Tiefenelektroden. Etwa ab Sekunde 8 ist deutlich Anfallsaktivität in den Hirnstrukturen, die von den Elektroden TL04 bis TL07 aufgezeichnet werden, zu erkennen.

6.2 Analyse des Elektroenzephalogramms

Ein epileptischer Anfall geht in vielen Fällen mit einer Beeinträchtigung oder dem Verlust des Bewusstseins einher. Darüber hinaus können - je nach betroffener Ge-

hirnregion - motorische Störungen auftreten, die Verletzungen oder Unfälle nach sich ziehen können. Falls eine medikamentöse Behandlung oder ein neurochirurgischer Eingriff nicht möglich ist, könnten die therapeutischen Möglichkeiten durch die Vorhersage epileptischer Anfälle enorm verbessert werden [Elg01]. Denkbar wären hier Warnsysteme, eine automatisierte und bedarfsgesteuerte Verabreichung von antiepileptischen Medikamenten oder Interventionssysteme, die z.B. mit elektrischer Stimulation des epileptischen Fokus arbeiten [TF04, Mor06, LLL07, SL08a].

In den letzten Jahren deuteten die Ergebnisse vieler Studien darauf hin, daß insbesondere Kenngrößen, die Interaktionen zwischen verschiedenen Hirnregionen quantifizieren, für die Detektion von möglichen Voranfallszuständen geeignet sind [MKR⁺05, LSN⁺05, ISP⁺05, LMO⁺07]. Insbesondere die verschiedenen Konzepte der Synchronisation [PRK01, BKO⁺02, LBH⁺09] erscheinen vielversprechend, nicht zuletzt da Synchronisation eine wichtige Rolle für die Funktionalität des Gehirns spielt und der epileptogene Prozess vermutlich auf Änderungen neuronaler Synchronisation basiert [VLRM01, Gla01, SG05, US06, Buz06]. Neben Studien, die auf symmetrischen nichtlinearen Interdependenzmaßen basieren [AGLE99, LAB⁺98, LMAV99, PRGG01, BT02b, BT02a, BTF⁺03, KES⁺04, Ost08], wurden in jüngster Zeit auch zunehmend direktionale Interaktionen zwischen Hirnstrukturen mit asymmetrischen nichtlinearen Interdependenzmaßen untersucht [AGLE99, PQB05, OMWL07, OMWL08]. Wie bereits erwähnt, weisen diese Maße durch die Suche nächster Nachbarn im Zustandsraum eine quadratische Abhängigkeit der benötigten Rechenzeit von der Anzahl der Sensoren auf, an denen Zeitreihen gemessen werden. Somit sind Anwendungen, für die Interdependenzmaße auf einem Computer in Echtzeit berechnet werden sollen, stark limitiert. In der vorliegenden Arbeit soll im folgenden daher überprüft werden, ob mit Hilfe von CNN symmetrische und asymmetrische Interdependenzmaße für Zeitreihen hirnelektrischer Aktivität mit ausreichender Genauigkeit approximiert werden können. Aufgrund der bereits zur Verfügung stehenden hardwaretechnischen Realisationen von CNN [LPKH02, LPKH04, RLC⁺04] könnte dies die Grundlage sein, in Zukunft miniaturisierte Analysesysteme beispielsweise zur Anfallsvorhersage zu entwickeln.

6.3 Datengrundlage

Für die Untersuchungen wurden quasikontinuierliche³ SEEG-Aufzeichnungen (siehe auch Abbildung 6.2) von drei Patienten mit einer durchschnittlichen Aufzeichnungsdauer von 106 Stunden verwendet. Während dieser Aufzeichnungen traten

³Die Aufzeichnungen waren teilweise durch Aufzeichnungslücken unterbrochen.

bei einem Patienten drei und bei zwei Patienten jeweils vier epileptische Anfälle auf.




Abbildung 6.2: Implantationsschema der Stabelektroden zur Aufzeichnung eines Stereo-Elektroenzephalogramms.

Die Stabelektroden in linker (TL) und rechter (TR) Hemisphäre waren jeweils mit zehn zylindrischen Kontakten aus einer Nickel-Chrom Legierung mit einer Länge von 2,5 mm und einem Durchmesser von 1 mm im Abstand von 4 mm zueinander ausgestattet. Es wurden für jeden Patienten SEEG-Zeitreihen an 20 Elektrodenkontakten (im folgenden kurz Elektroden genannt) TL01,...,TL10 sowie TR01,...,TR10 aufgezeichnet. Die Zeitreihen wurden dabei mit 200 Hz abgetastet (16-bit AD-Wandler) und in einem Bereich von 0,5 bis 85 Hz Bandpaß-gefiltert.

Die SEEG-Zeitreihen wurden in aufeinanderfolgende, nicht überlappende Segmente mit $M = 4096$ Datenpunkten (64×64 Zellen großes CNN) unterteilt, was einer Segmentdauer von 20,48 Sekunden entsprach. Dies stellte einen geeigneten Kompromiss zwischen einer ausreichenden Anzahl an Datenpunkten für eine statistisch zuverlässige Berechnung der Interdependenzmaße und approximativer Stationarität des dynamischen Systems Gehirn dar [BGQ⁺95, Pal96, RSA⁺02, RMA⁺03, RAML04, NL05].

Die analytische Berechnung sämtlicher nichtlinearer Interdependenzmaße in diesem Kapitel erfolgte gemäß Gleichung 2.34 mit den in [Ost08] ermittelten Parametern,

Anzahl nächste Nachbarn	$k = 6$
Einbettungsdimension	$m = 10$
Zeitversatz	$\tau = 5$ Datenpunkte
Theilerkorrektur	$\Lambda = 10$ Datenpunkte

Tabelle 6.1: Parameter für die Berechnung der Interdependenzmaße für die SEEG-Zeitreihen.

welche in Tabelle 6.1 aufgelistet sind. Im folgenden wird dabei stets eine verkürzte Schreibweise verwendet, wie z.B. N_s statt $N_s^{(6)}(X|Y)$.

Die Zustandsgleichung der CNN Zellen wurde mit einem Runge-Kutta Verfahren 4. Ordnung mit adaptiver Schrittweite integriert (das Verfahren wurde aus [PTVF02] mit den dort verwendeten Parametern entnommen). Das Integrationsintervall betrug $\tau_{trans} = 40$ [Sow04, SCML05, KCO⁺06, Kru06, KOEL07].

6.4 Zusammenstellung der Trainings- und Testmengen

Die Zusammenstellung der Trainingsmenge ist entscheidend, um ein optimales CNN zu finden, welches nichtlineare Interdependenzmaße approximieren kann. Besonders wichtig ist, die Wahrscheinlichkeit einer Überoptimierung möglichst zu verringern, was durch eine heterogene Verteilung von irrelevanten Eigenschaften der Zeitreihen innerhalb der Trainingsmenge gewährleistet werden kann (siehe auch Abschnitt 3.5.2). So können beispielsweise unmittelbar aufeinanderfolgende Zeitreihensegmente sehr ähnliche Dynamiken aufweisen, die eine Überoptimierung begünstigen könnten. Die Zeitreihensegmente, welche jeweils in einer Trainingsmenge benutzt wurden, mussten daher einen zeitlichen Mindestabstand von 30 Minuten besitzen. Außerdem wurden in jeder Trainingsmenge SEEG-Zeitreihensegmente, die zu verschiedenen Tages- und Nachtzeiten aufgezeichnet wurden, verwendet. Schließlich wurden alle Zeitreihensegmente, die in die Trainingsmenge aufgenommen werden sollten, vorher visuell auf Artefakte untersucht, die durch den Verstärker verursacht wurden (Clippings, langsame Drifts, Netzbrummen). Sämtliche Trainingsmengen wurden aus $M_{tr} = 16$ Elementen, also Paaren von SEEG-Zeitreihen mit einer Dauer von insgesamt nur etwa 5,5 Minuten, zusammengestellt [Sow04, SCML05, KOEL07]. Analog wurden die Testmengen ebenfalls aus $M_{te} = 16$ Paaren von Zeitreihensegmenten unter Berücksichtigung der genannten Kriterien zur Vermeidung von Überoptimierungen gebildet.

Die evolutionären Optimierungsverfahren wurden im folgenden jeweils mit den in Tabelle 6.2 aufgelisteten Parametern durchgeführt.

Evolutionsschritte pro Trainingsschritt	$M_s = 20$
Trainingsschritte	$M_g = 400$
Evolutionsschritte insgesamt	$M_g M_s = 8000$
Populationsgröße	$M_i = 50$
Überlebende pro Evolutionsschritt	$M_u = 10$
Mutierte Individuen pro Evolutionsschritt	$M_m = 30$
Immigranten pro Evolutionsschritt	$M_n = 10$

Tabelle 6.2: Parameter des evolutionären Optimierungsverfahrens.

6.5 Validierung

Aufgrund der Tatsache, daß Artefakte in den SEEG-Aufzeichnungen häufig zu besonders niedrigen oder hohen Werten der nichtlinearen Interdependenzmaße führen⁴, die außerhalb der Verteilung der Werte für die Zeitreihensegmente ohne Artefakte liegen, wurden vor der Validierung für jede Elektrodenkombination jeweils 2,5% der Zeitreihensegmente mit den höchsten bzw. niedrigsten Werte des analytisch berechneten Interdependenzmaßes entfernt. Dieses Vorgehen wurde gewählt, da aufgrund der großen Anzahl und Dauer von SEEG-Aufzeichnungen, die untersucht wurden, keine manuelle Artefaktkontrolle wie bei der Zusammenstellung von Trainings- und Testmengen angewendet werden konnte. Da eine automatisierte Artefaktkontrolle, die mit hoher Sensitivität und Spezifität beispielsweise Verstärkerartefakte erkennt, sehr schwierig zu implementieren ist, wurde in der vorliegenden Arbeit darauf verzichtet. Wenn eine Validierung mit Zeitreihen einer anderen als der zur Optimierung verwendeten Elektrodenkombination durchgeführt wurde, so wurde deren Wertebereich $[I_{min}; I_{max}]$ des analytisch berechneten Interdependenzmaßes zur Normierung der CNN-basierten Approximation genutzt. Für die analytisch berechneten Maßprofile der Interdependenzmaße I_i sowie die zugehörigen CNN-basierten Approximationen $I_i^{(CNN)}$, wurde durchgängig ein gleitender Mittelwert der Ordnung $\gamma = 15$ (entspricht etwa 5 Minuten) angewendet, da hier nur die

⁴Besonders hohe Werte werden z.B. bei symmetrischen Maßen dann erreicht, wenn Artefakte in beiden Zeitreihen gleichzeitig auftreten und somit zumindest abschnittsweise annähernd identische Zeitreihen erzeugen. Umgekehrt können Artefakte jedoch auch in nur einer der beiden Zeitreihen auftreten. Dann wird durch die sehr unterschiedlichen Zeitreihen ein sehr niedriger Wert des Interdependenzmaßes erreicht.

längerfristigen Fluktuationen der Interaktionsstärke bzw. -richtung von Interesse waren:

$$\begin{aligned} I_i^{(\gamma)} &= \frac{I_i + I_{i-1} + \dots + I_{i-\gamma+1}}{\gamma} \\ I_i^{(\text{CNN}),\gamma} &= \frac{I_i^{(\text{CNN})} + I_{i-1}^{(\text{CNN})} + \dots + I_{i-\gamma+1}^{(\text{CNN})}}{\gamma} \end{aligned} \quad (6.1)$$

Die Abweichung der CNN-basierten Approximation vom analytisch berechneten Interdependenzmaß $F^{(val)}$ wurde gemäß Gleichung 4.10 mit $I_i^{(\gamma)}$ bzw. $I_i^{(\text{CNN}),\gamma}$ berechnet:

$$F^{(val)} = \frac{1}{M_{val}(I_{max} - I_{min})} \sum_{i=1}^{M_{val}} \left| I_i^{(\gamma)} - I_i^{(\text{CNN}),\gamma} \right|. \quad (6.2)$$

Die über einen Validierungsdatensatz gemittelten analytisch berechneten Interdependenzmaße bzw. CNN-basierten Approximationen werden mit $I_{(mean)}$ bzw. $I_{(mean)}^{(\text{CNN})}$ bezeichnet und wie folgt definiert:

$$\begin{aligned} I_{(mean)} &= \frac{1}{M_{val}} \sum_{i=1}^{M_{val}} I_i \\ I_{(mean)}^{(\text{CNN})} &= \frac{1}{M_{val}} \sum_{i=1}^{M_{val}} I_i^{(\text{CNN})} \end{aligned} \quad (6.3)$$

6.6 Auswahl von CNN nach einem Optimierungsverfahren

In Voruntersuchungen wurde festgestellt, daß die CNN nach einem Optimierungsverfahren trotz eines geringen globalen Fehlers der Trainingsmenge $F^{(g)}$ meist ein schlechtes Validierungsergebnis (hoher Fehler $F^{(val)}$) zeigten und somit überoptimiert waren (siehe Abschnitt 3.5.2). Dies bedeutete, daß im Laufe des Optimierungsverfahrens eine weitere Verbesserung (d.h. ein kleinerer Fehler $F^{(g)}$) nur

durch Adaptierung spezifischer Eigenschaften der Elemente der Trainingsmenge erfolgte. Dieses - auch *Auswendiglernen* der Elemente genannte - Phänomen führte zu CNN ohne die gewünschten Generalisierungseigenschaften. Daraus resultierte die Notwendigkeit einer Prüfung der im Laufe des Optimierungsverfahrens bestimmten CNN, da a priori nicht klar war, ab welchem Trainingsschritt eine Überoptimierung einsetzte. Im folgenden wurde daher untersucht, ob durch Einführung einer Testmenge und dem entsprechenden Fehler $F^{(g,test)}$ eine während des Optimierungsverfahrens einsetzende Überoptimierung detektiert werden konnte. Dazu wurden in den hier durchgeführten Optimierungen die Templates der CNN nach jedem Trainingsschritt sowie der Fehler der Trainingsmenge $F^{(val)}$ und der Testmenge $F^{(g,test)}$ gespeichert. Da die Testmengen verglichen mit den Validierungsmengen eine wesentlich kleinere Anzahl von Elementen beinhalteten, stellte $F^{(g,test)}$ einen Schätzer für eine Überoptimierung dar. Der Vorteil bestand darin, daß die sehr zeitaufwändige Berechnung von $F^{(val)}$ aufgrund der großen Anzahl von Elementen einer Validierungsmenge nach jedem Trainingsschritt vermieden wurde, um festzustellen, ob ein CNN überoptimiert ist.

Im Folgenden wurde eine Untersuchung der Abhängigkeiten von globalem Fehler der Trainingsmenge $F^{(g)}$, globalem Fehler der Testmenge $F^{(g,test)}$ und dem tatsächlichen Validierungsergebnis $F^{(val)}$ exemplarisch an einer Beispieloptimierung durchgeführt. Dazu wurden Zeitreihensegmente der Elektrodenkombination TL01-TL02 eines Patienten für Trainings- und Testmenge genutzt und nach jedem Trainingsschritt $F^{(g)}$, $F^{(g,test)}$ sowie $F^{(val)}$ für das ermittelte CNN berechnet. Daraus wurden Erkenntnisse darüber gewonnen, welche Bewertungen $F^{(g)}$ bzw. $F^{(g,test)}$ vielversprechend erschienen, um die Wahl von CNN bei allen weiteren Optimierungsvorgängen in dieser Arbeit möglichst effektiv zu gestalten. Das Optimierungsverfahren wurde mit den in Tabelle 6.3 aufgelisteten Einstellungen durchgeführt.

Trainingsmenge	
Elemente mit niedrigen Werten N_s	8 mit $N_s \in [0, 131; 0, 182]$
Elemente mit hohen Werten N_s	8 mit $N_s \in [0, 949; 0, 991]$
Testmenge	
Elemente mit niedrigen Werten N_s	8 mit $N_s \in [0, 143; 0, 194]$
Elemente mit hohen Werten N_s	8 mit $N_s \in [0, 927; 0, 983]$

Tabelle 6.3: Informationen zur Zusammenstellung der Trainings- und Testmenge.

Für die Validierung wurde ein SEEG-Ausschnitt von $M_{val} = 4216$ Paaren von Zeitreihensegmenten, also circa 24 Stunden Dauer, der Elektrodenkombination TL01-TL02 des gleichen Patienten herangezogen. Die Abhängigkeit des Validierungsfehlers $F^{(val)}$ von globalem Fehler der Trainingsmenge $F^{(g)}$ bzw. Testmenge

$F^{(g,test)}$ ist in Abbildung 6.3 dargestellt.




Abbildung 6.3: Abhängigkeit des Validierungsergebnisses vom globalen Fehler der Trainingsmenge und globalen Fehler der Testmenge.

Auffällig war hier zunächst eine Häufung im Bereich von $F^{(g)} \approx 0$. Dies war damit zu erklären, daß das evolutionäre Minimierungsverfahren nach relativ wenigen Trainingsschritten Minima gefunden hatte, welche mehr oder weniger unverändert das Ergebnis aller folgenden Trainingsschritte blieben, wenn keine besseren Templates gefunden wurden. Bezüglich des Fehlers $F^{(g,test)}$ für die Elemente der Testmenge konnte diese Häufung in zwei Klassen unterteilt werden. Zum einen Templates mit $F^{(g,test)} \approx 0,5$ und⁵ zum anderen mit $F^{(g,test)} \approx 0$. Erstere wiesen demnach eine Überoptimierung für die Elemente der Trainingsmenge auf. Letztere dagegen funktionierten sowohl für die Elemente der Trainings- als auch der Testmenge mehr oder weniger perfekt. Dennoch besaßen die meisten dieser Templates eine vergleichsweise schlechte Bewertung bei der Validierung $F^{(val)} > 0,2$. Die wenigen Templates in diesem Bereich, welche eine gute Bewertung bei der Validierung von $F^{(val)} \approx 0,1$ erreichten, per Stichprobe zu finden, war sehr unwahrscheinlich.

Die genannten Zahlenwerte konnten lediglich als grober Anhaltspunkt angesehen werden, da eine Untersuchung vieler Optimierungsvorgänge notwendig gewesen

⁵Bewertungen von $F^{(g,test)} \approx 0,5$ entsprechen Templates, die unabhängig von den Zeitreihen nach dem Integrationsintervall τ_{trans} ein entweder vollständig schwarzes oder vollständig weißes Ausgabebild annahmen und somit genau für die Hälfte der Elemente der Testmenge korrekt arbeiteten.

wäre, um statistisch zuverlässige Aussagen zu erhalten, was aufgrund der benötigten Rechenzeit nicht möglich war. In allen folgenden Optimierungsverfahren wurden daher jeweils 3 Stichproben von CNN aus den genannten Wertebereichen von $0,05 < F^{(g)} < 0,2$ sowie $0,1 < F^{(g, test)} < 0,2$ für eine Validierung herangezogen und das jeweils beste vorgestellt.

6.7 Charakterisierung der Stärke von Interaktionen in Zeitreihen hirnelektrischer Aktivität

In diesem Abschnitt soll die Eignung von CNN zur Charakterisierung der Stärke von Interaktionen zwischen Hirnstrukturen nachgewiesen werden. In [Sow04] konnte ein Maß für Phasensynchronisation für Zeitreihen benachbarter Elektrodenkombinationen einzelner Patienten erfolgreich mit CNN geschätzt werden. In [Kru06] konnte erstmals nachgewiesen werden, daß auch ein Maß für nichtlineare Interdependenz - also ein Schätzer für den Grad generalisierter Synchronisation - mit CNN approximiert werden kann. In [KOEL07] gelang mit Hilfe des in Abschnitt 4.3 vorgestellten Optimierungsverfahrens ebenfalls der Nachweis, daß eine Charakterisierung der Interaktionsstärke zwischen strukturell unterschiedlichen Modellsystemen mit CNN mit hoher Zuverlässigkeit möglich ist. Daher wurde im folgenden Abschnitt unter anderem untersucht, ob CNN in der Lage sind, die Interaktionsstärke zwischen funktionell unterschiedlichen Hirnstrukturen zu charakterisieren.

In den folgenden Untersuchungen wurde durchgängig das symmetrische nichtlineare Interdependenzmaß N_s gemäß Gleichung 2.34 als Maß für Interaktionsstärke verwendet. Als Datengrundlage dienten die SEEG-Aufzeichnungen der drei bereits erwähnten Patienten (siehe Abschnitt 6.3). Bei allen Patienten wurde eine Schläfenlappenepilepsie diagnostiziert. Bei Patient A erfassten dabei alle Elektroden, die in der rechten Hemisphäre implantiert waren, den epileptischen Fokus. Bei Patient B lagen die Elektroden TR04 bis TR08 im epileptischen Fokus. Der epileptische Fokus von Patient C wurde von der Elektroden TL04 bis TL08 erfasst. Während die Patienten A und B nach der Resektion des epileptischen Fokus anfallsfrei blieben, traten bei Patient C postoperativ deutlich seltener Anfälle auf.

Bei der Nennung der Elektrodenkombinationen gilt im folgenden die Konvention, daß die erste genannte Elektrode bei der analytischen Berechnung der nichtlinearen Interdependenzmaße System X entspricht und die zweite System Y . Für die CNN-basierte Approximation wurden die Zeitreihen der zuerst genannten Elektrode den Eingängen der CNN-Zellen zugewiesen und die Zeitreihen der als zweites genannten

dem Anfangszustand. Die Templates sämtlicher im folgenden gezeigten CNN sind in Anhang B aufgelistet.

6.7.1 Optimierung und Validierung mit Zeitreihen einzelner Elektrodenkombinationen individueller Patienten

Da in der folgenden Untersuchung überprüft werden sollte, ob CNN die Interaktionsstärke zwischen verschiedenen Hirnstrukturen schätzen können, wurden je Patient drei CNN anhand von SEEG-Zeitreihen von verschiedenen Elektrodenkombinationen optimiert. Für Patient A wurden innerhalb der dem epileptischen Fokus gegenüberliegenden - kontralateralen - Hemisphäre eine Kombination aus benachbarten Elektroden (TL05-TL06) sowie eine Kombination aus entfernt gelegenen Elektroden (TL03-TL09) gewählt. Die Elektroden TL05 und TL06 zeichneten dabei zum Teil die Aktivität der gleichen Hirnstrukturen auf, während bei TL03 und TL09 davon ausgegangen werden konnte, daß aufgrund des räumlichen Abstandes im Wesentlichen die Aktivität verschiedener Neuronenverbände erfasst wurde. Als dritte Elektrodenkombination wurde TR02-TR07 gewählt, wobei sowohl TR02 als auch TR07 die hirnelektrische Aktivität des epileptischen Fokus aufzeichneten. Für Patient B wurde mit TR09-TL03 eine interhemisphärische Elektrodenkombination untersucht, um herauszufinden, ob CNN auch die Interaktionsstärke zwischen beiden Hirnhälften schätzen können. Mit der Elektrodenkombination TR10-TR06 wurde die Interaktion zwischen dem epileptischen Fokus (TR06) und einer anderen Hirnstruktur der fokalen Hemisphäre charakterisiert. Die Elektrodenkombination TL05-TL09 wurde gewählt, um zu überprüfen, ob das CNN auch die Interaktionsstärke innerhalb der kontralateralen Hemisphäre schätzen kann. Für Patient C wurden zwei interhemisphärische Elektrodenkombinationen untersucht (TL03-TR10 und TL07-TR08), wobei TL07 die Aktivität des epileptischen Fokus aufzeichnete. Zusätzlich wurde eine Kombination aus benachbarten Elektroden der kontralateralen Hemisphäre (TR02-TR03) untersucht.

Die Validierung der jeweils optimierten CNN erfolgte für Patient A mit SEEG-Aufzeichnungen von ca. 116 Stunden Dauer, für Patient B mit etwa 50 Stunden Dauer und für Patient C mit ca. 152 Stunden Dauer. Es wurden jeweils die Aufzeichnungen der gleichen Elektrodenkombination zur Validierung herangezogen, mit denen das CNN optimiert wurde. Die Ergebnisse der Validierung sind in Tabelle 6.4 aufgelistet. Die Bezeichnungen der CNN - wie zum Beispiel CNN(s, Pat A, TL03-TL09) sind dabei wie folgt zu verstehen: Das erste Argument „s“ gibt an, daß das CNN mit dem symmetrischen Interdependenzmaß N_s optimiert wurde. Die zweiten und dritten Argumente zeigen an, von welchem Patienten und von welcher Elektro-

denkombination die Zeitreihen stammten, die zur Optimierung des CNN verwendet wurden.

CNN	Pat.	Validierung Elektrodenkomb.	Approximations- fehler $F^{(val)}$
CNN(s, Pat A, TL03-TL09)	A	TL03-TL09	11,1%
CNN(s, Pat A, TL05-TL06)	A	TL05-TL06	14,6%
CNN(s, Pat A, TR02-TR07)	A	TR02-TR07	26,2%
CNN(s, Pat B, TR09-TL03)	B	TR09-TL03	6,9%
CNN(s, Pat B, TR10-TR06)	B	TR10-TR06	14%
CNN(s, Pat B, TL05-TL09)	B	TL05-TL09	10,7%
CNN(s, Pat C, TL03-TR10)	C	TL03-TR10	14%
CNN(s, Pat C, TL07-TR08)	C	TL07-TR08	13,4%
CNN(s, Pat C, TR02-TR03)	C	TR02-TR03	13,3%

Tabelle 6.4: CNN, die in den Optimierungen mit Zeitreihen einzelner Elektrodenkombinationen bestimmt werden konnten. Approximationsfehler (rechts) für die Zeitreihen der angegebenen Elektrodenkombination des jeweiligen Patienten (Mitte).

Das analytisch berechnete Interdependenzmaß sowie die CNN-basierte Approximation mit CNN(s, Pat A, TL03-TL09) sind in Abbildung 6.4 gezeigt. Hier ist zu erkennen, daß das CNN in der Lage war, die Interaktionsstärke zwischen den Hirnstrukturen selbst über einen Zeitraum von Tagen mit einer hohen Güte zu schätzen. Hierbei konnten sowohl langfristige (siehe oberer Ausschnitt in Abbildung 6.4) als auch kurzfristige (siehe andere Ausschnitte in Abbildung 6.4) Fluktuationen der Interaktionsstärke reproduziert werden. Auffällig war lediglich die etwas größere Abweichung während der ersten 40 Stunden der Aufzeichnung. Hier zeigte sich eine permanente Unterschätzung des Synchronisationsniveaus (siehe auch unterer Ausschnitt in Abbildung 6.4), was auf einen Wechsel der Referenzelektrode bei der SEEG-Aufzeichnung zurückgeführt werden konnte. Allerdings ist zu erkennen, daß dennoch meist kurzfristige Anstiege oder Abfälle der Interaktionsstärke korrekt mit CNN(s, Pat A, TL03-TL09) reproduziert wurden.

In Abbildung 6.5 sind das analytisch berechnete Interdependenzmaß sowie die CNN-basierte Approximation mit CNN(s, Pat A, TR02-TR07) gezeigt, welches einen Approximationsfehler von $F^{(val)}_{(TR02-TR07)} = 26,2\%$ aufwies⁶. Es ist zu erkennen, daß kurzfristige Fluktuationen der Interaktionsstärke zwar zuverlässig mit dem

⁶Im folgenden wird der Approximationsfehler, der mit den Zeitreihen einer Elektrodenkombination berechnet wurde, mit einem entsprechenden Index gekennzeichnet.

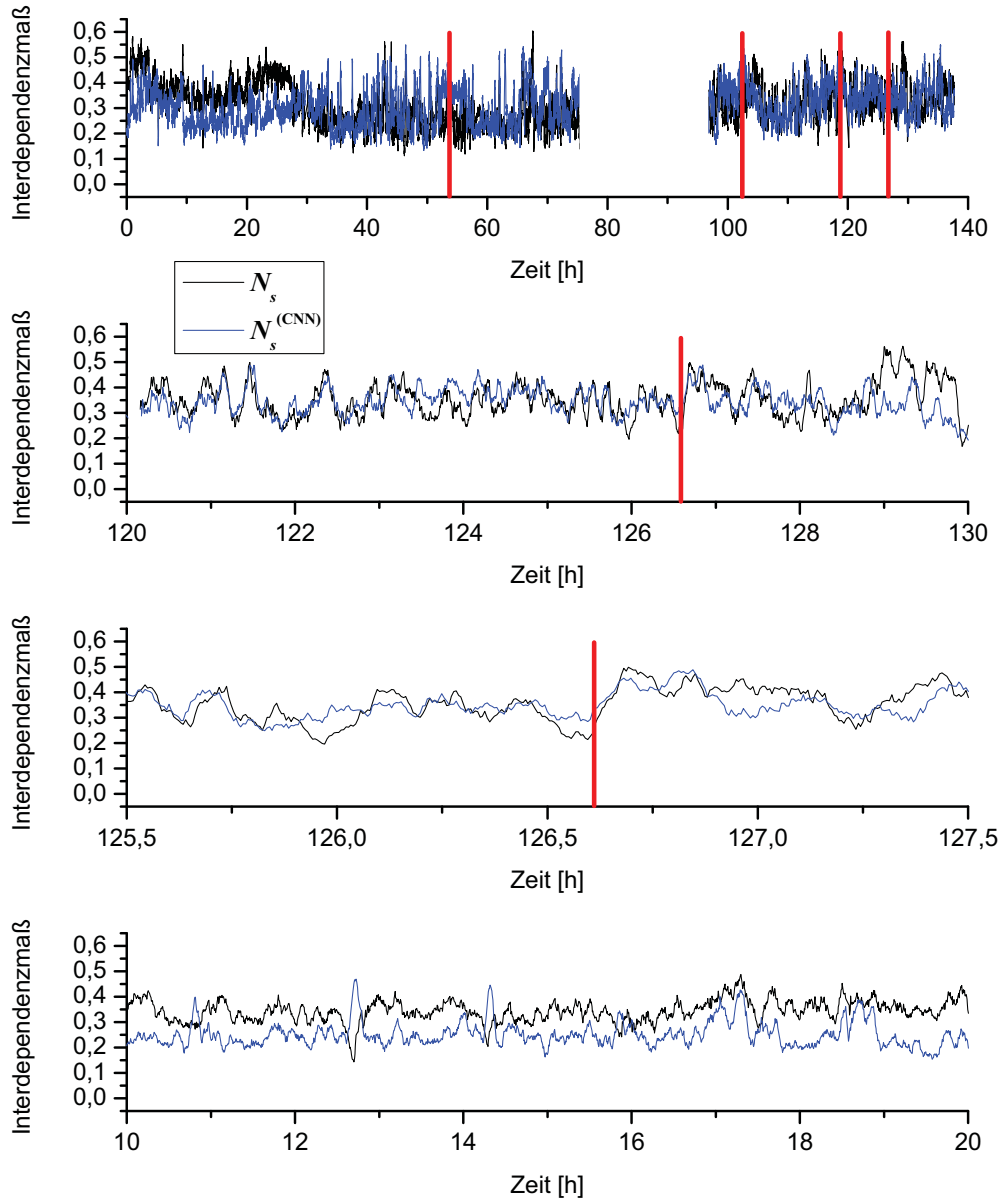


Abbildung 6.4: Oben: Zeitlicher Verlauf des analytisch berechneten Interdependenzmaßes sowie der Approximation mit CNN(s, Pat A, TL03-TL09) für eine etwa 116 Stunden dauernde SEEG-Aufzeichnung (Elektrodenkombination TL03-TL09 von Patient A), darunter Ausschnitte. Rote Markierungen entsprechen elektrischem Anfallsbeginn. Größere Aufzeichnungslücke nach 75 Stunden.

CNN reproduziert werden konnten, jedoch ein über den gesamten analysierten Datensatz zu niedriges Niveau der Interaktionsstärke geschätzt wurde. Dies war auf ein CNN-Template zurückzuführen, welches eine generelle Tendenz zu Zellausgaben $v = -1$ besaß.

Das analytisch berechnete Interdependenzmaß sowie die CNN-basierte Approximation mit CNN(s, Pat B, TR09-TL03) sind in Abbildung 6.6 dargestellt. Es ist zu erkennen, daß das CNN in der Lage war, sowohl kurz- als auch langfristige Fluktuationen der Interaktionsstärke mit hoher Genauigkeit zu schätzen.

Im Gegensatz zu den Optimierungen mit Zeitreihen von Patient A, konnte mit CNN(s, Pat B, TR10-TR06) für Patient B auch nach einer Optimierung mit SEEG-Zeitreihen einer fokalen Elektrode (TR06) ein CNN gefunden werden, welches die Interaktionsstärke zwischen den analysierten Hirnstrukturen zuverlässig schätzen konnte (siehe Abbildung 6.7). Dies wurde als Nachweis gewertet, daß CNN auch die Dynamik einer pathologisch veränderten Hirnstruktur erlernen können. Dabei konnten sowohl lang- als auch kurzfristige Fluktuationen der Interaktionsstärke zuverlässig reproduziert werden.

In Abbildung 6.8 ist das analytisch berechnete sowie das mit CNN(s, Pat C, TL07-TR08) approximierte Interdependenzmaß für Zeitreihen der interhemisphärischen Elektrodenkombination TL07-TR08 zu sehen (TL07 lag im epileptischen Fokus). Es ist zu erkennen, daß sowohl lang- als auch kurzfristige Fluktuationen der Interaktionsstärke sehr gut mit dem CNN reproduziert wurden. Auffällig war jedoch eine Überschätzung der Interaktionsstärke zwischen den Hirnstrukturen um die Elektroden TL07 bzw. TR08 durch das CNN in den letzten ca. 30 Stunden des analysierten Datensatzes (siehe oberen Ausschnitt in Abbildung 6.8). Dies könnte mit einer durch die auftretenden epileptischen Anfälle einhergehenden Änderung der Dynamik der analysierten Hirnstrukturen zusammenhängen. Diese konnte das CNN während der Optimierung nicht erlernen, da keine Zeitreihen aus diesem Zeitraum Teil der Trainingsmenge waren. Im unteren Teil von Abbildung 6.8 ist jedoch auch zu erkennen, daß die kurzfristigen Anstiege bzw. Abfälle der Interaktionsstärke durch das CNN reproduziert wurden.

Die Ergebnisse zeigen, daß CNN, die mit SEEG-Zeitreihen einzelner Elektrodenkombinationen der drei Patienten optimiert wurden, in der Lage waren, die Dynamik unterschiedlicher Hirnstrukturen zu erfassen und die Interaktionsstärke zwischen ihnen zuverlässig zu schätzen. Dabei konnten mit Optimierungen, die jeweils

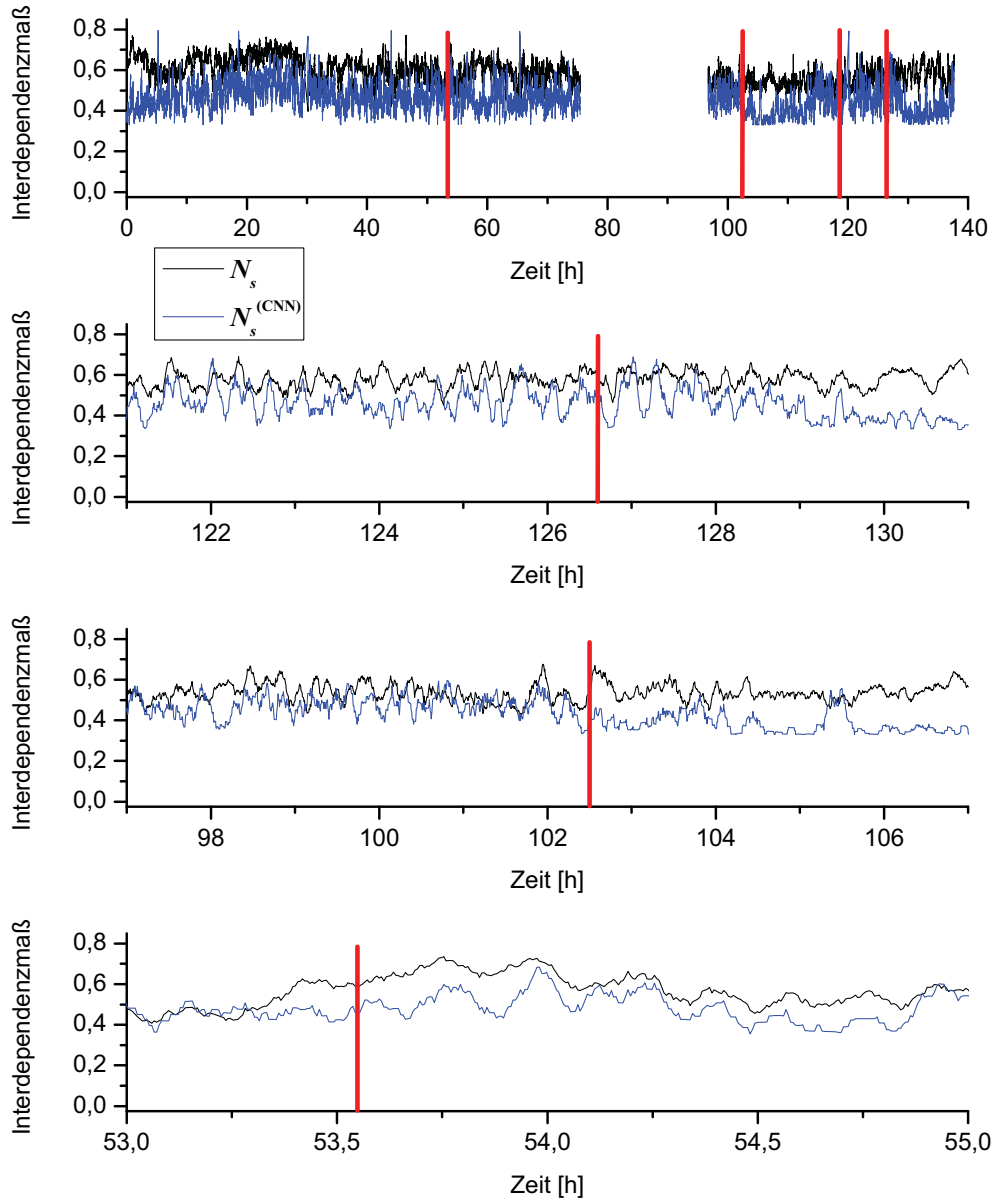


Abbildung 6.5: Wie Abbildung 6.4, jedoch für CNN(s, Pat A, TR02-TR07) und Zeitreihen der Elektrodenkombination TR02-TR07 von Patient A.

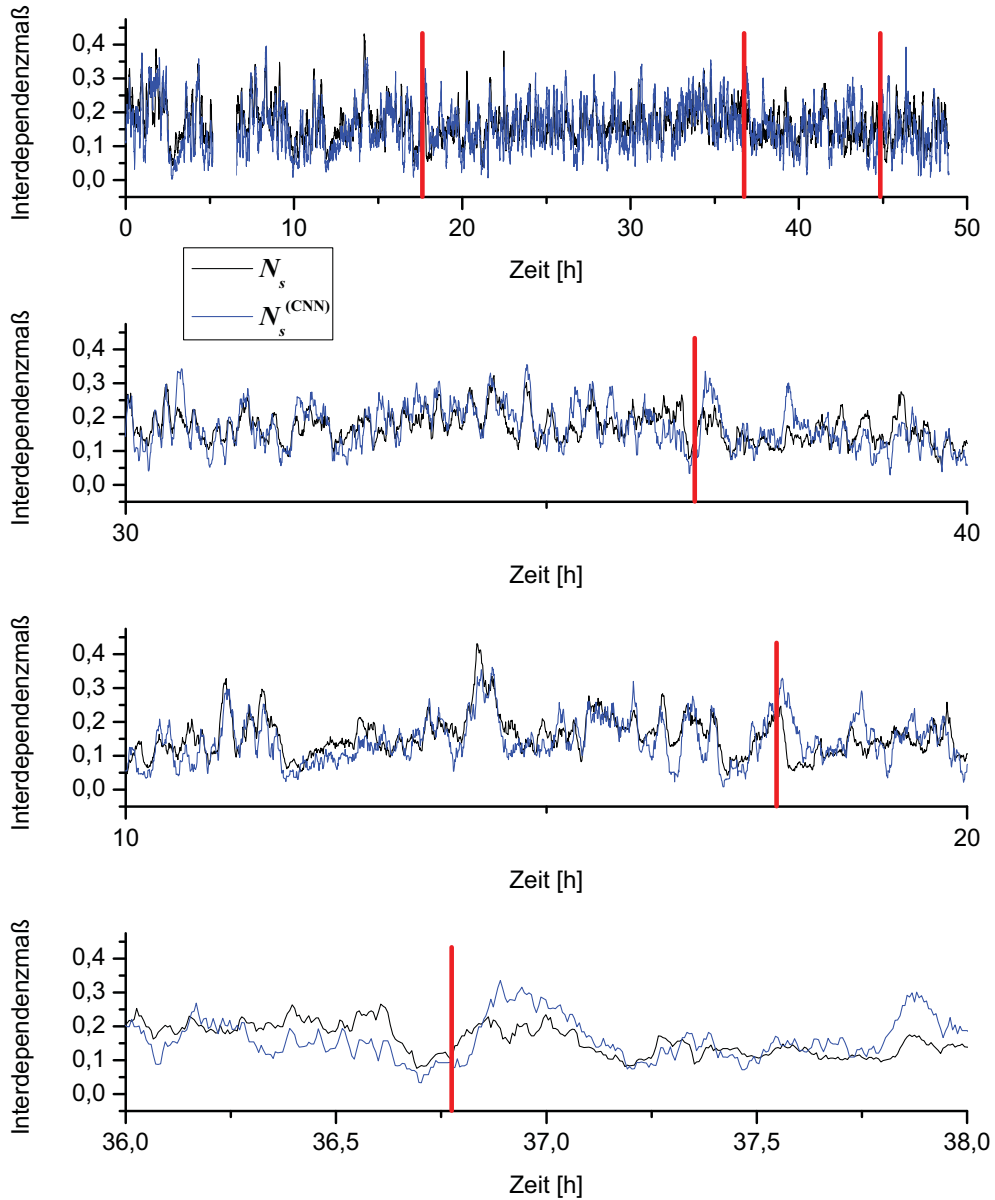


Abbildung 6.6: Oben: Zeitlicher Verlauf des analytisch berechneten Interdependenzmaßes sowie der Approximation mit CNN(s, Pat B, TR09-TL03) für eine etwa 50 Stunden dauernde SEEG-Aufzeichnung (Elektrodenkombination TR09-TL03 von Patient B), darunter Ausschnitte. Rote Markierungen entsprechen elektrischem Anfallsbeginn. Aufzeichnungslücke nach etwa 5 Stunden.

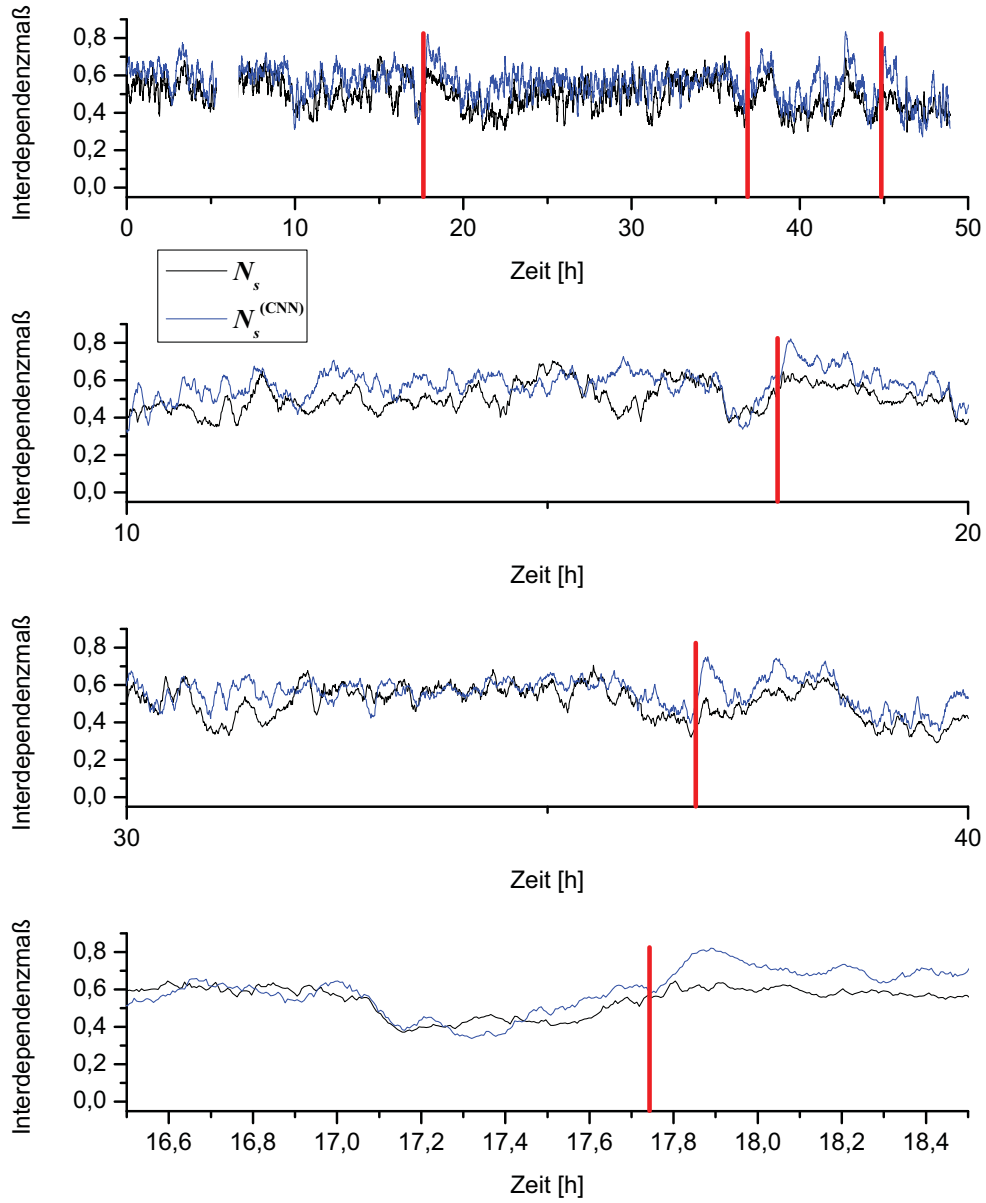


Abbildung 6.7: Wie Abbildung 6.6, jedoch für CNN(s, Pat B, TR10-TR06) und Zeitreihen der Elektrodenkombination TR10-TR06 von Patient B.

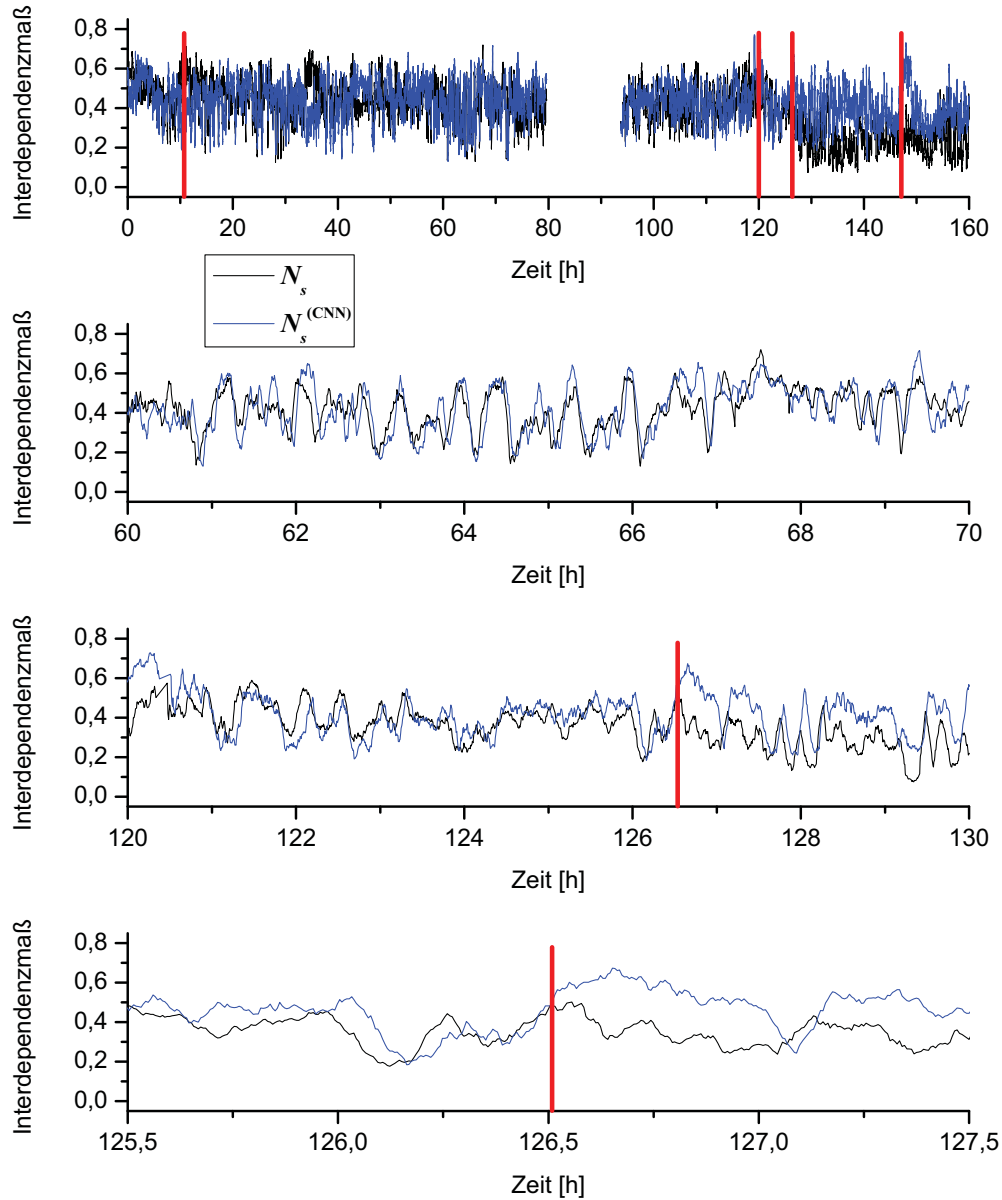


Abbildung 6.8: Oben: Zeitlicher Verlauf des analytisch berechneten Interdependenzmaßes sowie der Approximation mit CNN(s, Pat C, TL07-TR08) für eine etwa 152 Stunden dauernde SEEG-Aufzeichnung (Elektrodenkombination TL07-TR08 von Patient C), darunter Ausschnitte. Rote Markierungen entsprechen elektrischem Anfallsbeginn. Aufzeichnungslücke nach etwa 80 Stunden.

auf SEEG-Zeitreihen mit einer Gesamtdauer von lediglich ca. 5,5 Minuten basierten, für 8 von 9 Elektrodenkombinationen CNN gefunden werden, die Approximationsfehler von $F^{(val)} < 15\%$ aufwiesen (siehe Tabelle 6.4). Eine Schätzung der Interaktionsstärke war dabei ebenso zwischen benachbarten und entfernt gelegenen Hirnstrukturen innerhalb einer Hemisphäre möglich wie auch zwischen Hirnstrukturen in verschiedenen Hemisphären. Auch die Interaktion zwischen dem epileptischen Fokus mit einer pathologisch veränderten Dynamik und anderen Hirnstrukturen konnten CNN mit hoher Güte reproduzieren. Die Templates der hier gefundenen CNN (siehe Anhang B) wiesen keine Gemeinsamkeiten etwa beim Betrag oder den Vorzeichen der Koeffizienten auf. Somit konnten keine Hinweise auf ein universelles CNN gefunden werden.

6.7.2 Generalisierungseigenschaften

Im folgenden wurde untersucht, welche Generalisierungseigenschaften die zuvor bestimmten CNN besaßen. Dahinter stand die Fragestellung, inwieweit diese mit Zeitreihen einzelner Elektrodenkombinationen - d.h. einzelner Hirnstrukturen - optimierten CNN auch die Interaktionsstärke zwischen anderen Hirnstrukturen schätzen konnten. Darüber hinaus wurde ebenfalls untersucht, ob CNN sogar ohne individuelle Optimierung die Interaktionsstärke zwischen Hirnstrukturen für verschiedene Patienten schätzen konnten. Diese Fragestellungen haben unter anderem den Hintergrund, daß es für die Analyse von Felddaten vorteilhaft wäre, wenn das aufwändige Optimierungsverfahren nicht für jede Elektrodenkombination und jeden Patienten spezifisch durchgeführt werden müsste. In den vorliegenden SEEG-Aufzeichnungen von jeweils $n = 20$ Elektroden beispielsweise wären $n(n - 1) = 380$ Optimierungen notwendig, um geeignete CNN für sämtliche Elektrodenkombinationen zu erhalten.

Um die Generalisierungseigenschaften zu untersuchen, wurden zunächst die in Abschnitt 6.7.1 bestimmten CNN anhand der SEEG-Zeitreihen sämtlicher Elektrodenkombinationen aller drei Patienten validiert. Zu beachten ist bei den folgenden Untersuchungen eine im Vergleich zu den bisher gezeigten Validierungen verkleinerte Validierungsmenge, da durch die Berechnung von insgesamt 380 Elektrodenkombinationen der entsprechende Anstieg der benötigten Rechenzeit kompensiert werden musste⁷. Die analysierten SEEG-Aufzeichnungen hatten eine Dauer von etwa 18 Stunden für Patient A, etwa 16 Stunden für Patient B und etwa 12 Stunden

⁷An dieser Stelle sei nochmals erwähnt, daß der Geschwindigkeitsvorteil hardwaretechnischer Realisationen Zellulärer Neuroner Netze durch die Simulation am Rechner (siehe Abschnitt 4.2) nicht zum tragen kommt.

für Patient C. Die Datensätze beinhalteten dabei für jeden Patienten jeweils einen epileptischen Anfall.

Um die Approximationsgüte eines CNN für sämtliche Elektrodenkombinationen zu quantifizieren, wurde der durchschnittliche Approximationsfehler $F_M^{(val)}$ als Mittelwert der Approximationsfehler $F^{(val)}$ aller 380 Elektrodenkombinationen verwendet. In Tabelle 6.5 sind die mit CNN(s, Pat A, TL03-TL09), CNN(s, Pat B, TR09-TL03) sowie CNN(s, Pat C, TR02-TR03) erhaltenen Ergebnisse aufgelistet.

CNN	Validierung		Approximationsfehler $F_M^{(val)}$
	Pat.	Elektrodenkomb.	
CNN(s, Pat A, TL03-TL09)	A	alle	11,6%
CNN(s, Pat A, TL03-TL09)	B	alle	18,1%
CNN(s, Pat A, TL03-TL09)	C	alle	12,9%
CNN(s, Pat B, TR09-TL03)	A	alle	21,9%
CNN(s, Pat B, TR09-TL03)	B	alle	13%
CNN(s, Pat B, TR09-TL03)	C	alle	24,1%
CNN(s, Pat C, TR02-TR03)	A	alle	31%
CNN(s, Pat C, TR02-TR03)	B	alle	41,7%
CNN(s, Pat C, TR02-TR03)	C	alle	36,4%

Tabelle 6.5: CNN, die in den Optimierungen mit Zeitreihen einzelner Elektrodenkombinationen bestimmt werden konnten. Über alle Elektrodenkombinationen gemittelter Approximationsfehler (rechts) für die Zeitreihen des jeweiligen Patienten (Mitte).

CNN(s, Pat A, TL03-TL09) zeigte bei der Validierung mit den SEEG-Zeitreihen aller Elektrodenkombinationen von Patient A sehr gute Generalisierungseigenschaften ($F_M^{(val)} = 11,6\%$). Exemplarisch ist in Abbildung 6.9 ein Ausschnitt des analytisch berechneten Interdependenzmaßes sowie der CNN-basierten Approximation der interhemisphärischen Elektrodenkombination TL02-TR09 gezeigt. Es wird deutlich, daß das CNN in der Lage war, die Interaktionsstärke mit hoher Güte zwischen Hirnstrukturen zu schätzen, deren Zeitreihen nicht Teil der Trainingsmenge waren.

CNN(s, Pat A, TL03-TL09) zeigte ähnlich gute Approximationsgüten für die Zeitreihen von Patient C ($F_M^{(val)} = 12,9\%$). Exemplarisch ist ein Ausschnitt von analytisch berechnetem Interdependenzmaß und CNN-basierter Approximation für die Zeitreihen der Elektrodenkombination TR03-TR09 in Abbildung 6.9 gezeigt. Es ist zu erkennen, daß das CNN auch für die Zeitreihen eines Patienten, dessen




Abbildung 6.9: Zeitlicher Verlauf des analytisch berechneten Interdependenzmaßes sowie der Approximation mit CNN(s, Pat A, TL03-TL09) für eine etwa 18 Stunden dauernde SEEG-Aufzeichnung der Elektrodenkombination TL02-TR09 von Patient A (oben) und für eine etwa 12 Stunden dauernde SEEG-Aufzeichnung der Elektrodenkombination TR03-TR09 von Patient C (unten), rote Markierungen entsprechen elektrischem Anfallsbeginn.

Daten nicht Teil der Trainingsmenge waren, die Interaktionsstärke mit einem sehr geringen Fehler schätzen konnte ($F_{(TR03-TR09)}^{(val)} = 6,1\%$).

Ein Gesamtbild der Approximationsfehler für die Zeitreihen sämtlicher Elektrodenkombinationen der drei untersuchten Patienten ist in Abbildung 6.10 gezeigt⁸. Für Patient A ergaben sich für die meisten Elektrodenkombinationen hohe Approximationsgüten ($F_M^{(val)} = 11,6\%$). Lediglich für räumlich benachbarte Elektroden innerhalb der linken (kontralateralen) Hemisphäre ergaben sich Approximationsfehler von $F^{(val)} > 20\%$. Die dabei in Abbildung 6.10 an den Elektroden TL01 bis TL04 bzw. TL05 bis TL08 zu erkennenden Blöcke mit hohen Approximationsfehlern deuteten auf eine Differenzierung verschiedener funktioneller Hirnareale hin (Amygdala für die Elektroden TL01 bis TL04 und Hippocampus TL05 bis TL08) innerhalb derer unter Umständen eine sehr ähnliche Dynamik auftritt. Das CNN konnte dementsprechend gerade für sehr ähnliche Zeitreihen keine gute Approximation der Interaktionsstärke bieten. Für Patient C zeigte sich ein ähnliches Bild.

⁸In den Abbildungen entsprechen die Zeitreihen der Elektroden in vertikaler Richtung System X und in horizontaler Richtung System Y.

Hier wurden ebenfalls für räumlich benachbarte Elektroden teilweise sehr große Approximationsfehler beobachtet - insbesondere im Bereich des epileptischen Fokus (Elektroden TL04 bis TL08). Für Patient B ergab sich allerdings ein etwas anderes Bild. Hier konnte CNN(s, Pat A, TL03-TL09) insbesondere für interhemisphärische Elektrodenkombinationen keine guten Approximationen bieten und war somit kein zuverlässiger Schätzer der Interaktionsstärke ($F_M^{(val)} = 18,1\%$). Insgesamt zeigte CNN(s, Pat A, TL03-TL09) teilweise gute Generalisierungseigenschaften für Zeitreihen aus anderen Hirnstrukturen des Patienten, dessen Zeitreihen für die Optimierung verwendet wurden, und sogar für die Zeitreihen eines anderen Patienten.

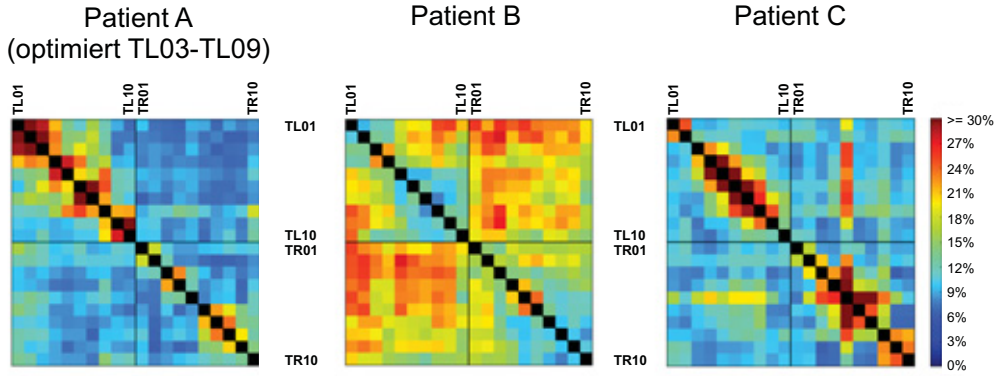


Abbildung 6.10: Approximationsfehler $F^{(val)}$ mit CNN(s, Pat A, TL03-TL09) farbkodiert für die Zeitreihen aller Elektrodenkombinationen der Patienten A, B und C.

Die Validierung von CNN(s, Pat B, TR09-TL03) ergab gute Approximationsergebnisse für die Zeitreihen aller Elektrodenkombinationen von Patient B. Bei der Analyse der Zeitreihen der Patienten A und C zeigte sich jedoch nur teilweise eine ausreichende Approximationsgüte (siehe Abbildung 6.11). Das CNN wies demnach eine Adaption auf die Dynamik der Hirnregionen von Patient B auf, in denen die Zeitreihen aufgezeichnet wurden, welche zur Optimierung des CNN verwendet wurden. Auffällig waren wiederum die Blöcke mit sehr hohen Approximationsfehlern im Bereich der Elektroden TL01 bis TL04 bzw. TL05 bis TL08 für die Zeitreihen von Patient A, was wieder auf eine Differenzierung von Amygdala und Hippocampus hindeute.

Bei der Validierung von CNN(s, Pat C, TR02-TR03) konnte für alle Patienten eine gute Approximation nur für räumlich benachbarte Elektrodenkombinationen be-

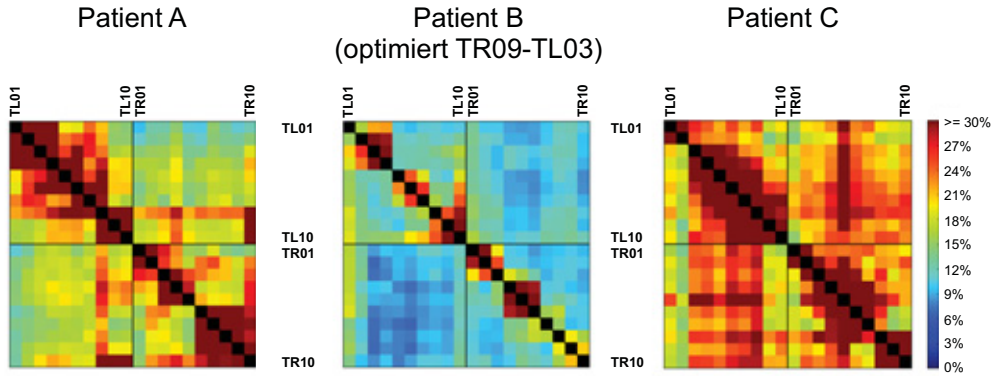


Abbildung 6.11: Approximationsfehler $F^{(val)}$ mit CNN(s, Pat B, TR09-TL03) farbkodiert für die Zeitreihen aller Elektrodenkombinationen der Patienten A, B und C.

obachtet werden (siehe Abbildung 6.12). Das CNN hat offensichtlich aufgrund der Optimierung mit Zeitreihen, die an benachbarten Elektroden aufgezeichnet wurden, eine Regel erlernt, mit der die Interaktionsstärke zwischen unterschiedlichen Hirnstrukturen nicht zuverlässig geschätzt werden konnte.

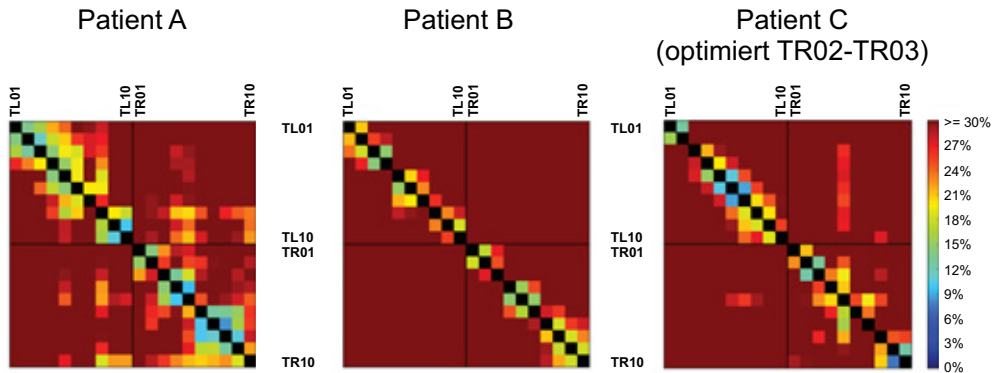


Abbildung 6.12: Approximationsfehler $F^{(val)}$ mit CNN(s, Pat C, TR02-TR03) farbkodiert für die Zeitreihen aller Elektrodenkombinationen der Patienten A, B und C.

Die Generalisierungseigenschaften von CNN, die mit Zeitreihen trainiert wurden, welche von einzelnen Elektrodenkombinationen stammten, zeigten ein uneinheitliches Bild. So konnten teilweise gute Approximationsgüten für andere Hirnstrukturen festgestellt werden, wobei diese in einem Fall sogar für einen Patienten galten,

dessen Zeitreihen nicht Teil der Trainingsmenge waren. Auffällig war jedoch, daß bei allen CNN besonders gut Zeitreihen von räumlich benachbarten und besonders schlecht Zeitreihen von räumlich entfernt gelegenen Kombinationen von Elektroden verarbeitet wurden oder umgekehrt. Dies hing unmittelbar davon ab, ob die Optimierung mit Zeitreihen durchgeführt wurde, die von benachbarten oder entfernt gelegenen Elektroden stammten. Dies bedeutete, daß das CNN durch Optimierungen mit Daten einzelner Elektrodenkombinationen nicht zuverlässig eine Regel erlernen konnte, die eine Schätzung der Interaktionsstärke zwischen sämtlichen untersuchten Hirnstrukturen bieten konnte.

Aufgrund dieser Ergebnisse wurde untersucht, ob durch Optimierungen mit Zeitreihen, die von verschiedenen Elektrodenkombinationen stammten, eine Verbesserung der Generalisierungseigenschaften erreicht werden konnte. Durch Trainings- und Testmengen, die sowohl Zeitreihen von benachbarten als auch von entfernt gelegenen Elektroden enthielten, sollte eine Adaption der Interaktion einzelner Hirnstrukturen vermieden und den CNN das Erlernen einer allgemeinen Regel ermöglicht werden. Hierzu wurden einerseits für die drei Patienten A, B und C jeweils Optimierungen mit Zeitreihen verschiedener Elektrodenkombinationen durchgeführt (siehe CNN(s, Pat A, M), CNN(s, Pat B, M), CNN(s, Pat C, M) in Tabelle 6.6). Schließlich wurde mit CNN(s, M, M) noch ein CNN mit Zeitreihen verschiedener Elektrodenkombinationen von den drei Patienten A, B und C optimiert⁹.

Die Wahl der Elektrodenkombinationen, an denen die Zeitreihen aufgezeichnet wurden, welche zur Optimierung benutzt wurden, erfolgte zufällig. Allerdings wurden jeweils sowohl räumlich benachbarte sowie entfernt gelegene Kombinationen von Elektroden verwendet. Außerdem wurden jeweils interhemisphärische sowie intrahemisphärische Elektrodenkombinationen (beider Hemisphären) sowie Kombinationen mit Elektroden, die die Aktivität des epileptischen Fokus aufzeichneten, gewählt. So konnte eine möglichst breite Verteilung der Dynamiken der verschiedenen Hirnstrukturen für die jeweils $M_{tr} = 16$ Elemente der Trainingsmengen (und der $M_{te} = 16$ Elemente der Testmengen) gewährleistet werden.

Durch die Optimierung mit Zeitreihen von Patient A konnte mit CNN(s, Pat A, M) ein CNN gefunden werden, welches einen Approximationsfehler für sämtliche Elektrodenkombinationen von $F_M^{(val)} = 18,1\%$ für Patient A aufwies. In Abbildung 6.13 ist zu erkennen, daß die Dynamik der linken Hemisphäre nicht ausreichend adaptiert wurde, was sich in hohen Approximationsfehlern für die entsprechenden intrahemisphärischen Elektrodenkombinationen äußerte. Zusätzlich sind in Abbil-

⁹In den Bezeichnungen der CNN steht „M“ für *mixed*, also für eine Optimierung mit Zeitreihen verschiedener Elektrodenkombinationen bzw. verschiedener Patienten.

CNN	Validierung		Approximationsfehler $F_M^{(val)}$
	Patient	Elektrodenkomb.	
CNN(s, Pat A, M)	A	alle	18,1%
CNN(s, Pat A, M)	B	alle	30,3%
CNN(s, Pat A, M)	C	alle	21,1%
CNN(s, Pat B, M)	A	alle	25,5%
CNN(s, Pat B, M)	B	alle	14,1%
CNN(s, Pat B, M)	C	alle	19,2%
CNN(s, Pat C, M)	A	alle	11,4%
CNN(s, Pat C, M)	B	alle	10,2%
CNN(s, Pat C, M)	C	alle	10,6%
CNN(s, M, M)	A	alle	11%
CNN(s, M, M)	B	alle	14%
CNN(s, M, M)	C	alle	12,4%

Tabelle 6.6: CNN, die in den Optimierungen mit Zeitreihen verschiedener Elektrodenkombinationen bestimmt werden konnten. Über alle Elektrodenkombinationen gemittelter Approximationsfehler (rechts) für die Zeitreihen des jeweiligen Patienten (Mitte).

dung 6.13 die über den analysierten Datensatz gemittelten Werte $N_{s,(mean)}$ und $N_{s,(mean)}^{(CNN)}$ je Elektrodenkombination dargestellt (siehe Gleichung 6.3). Hieran ist abzulesen, daß das CNN trotz der teilweise hohen Approximationsfehler $F^{(val)}$ aufgrund der schlecht reproduzierten kurzfristigen Fluktuationen in der Lage war, das mittlere Niveau der Interaktionsstärke recht gut zu schätzen. So ist in Abbildung 6.13 für das nichtlineare Interdependenzmaß beispielsweise eine höhere Interaktionsstärke innerhalb der fokalen Hemisphäre gegenüber der kontralateralen zu erkennen, was in Übereinstimmung mit Beobachtungen früherer Arbeiten stand [AGLE99, LMAV99]. Außerdem war eine deutlich geringere Interaktionsstärke zwischen den interhemisphärischen Kombinationen der Elektroden TL01 bis TL07 zu erkennen. Beide Effekte wurden trotz der teilweise hohen Approximationsfehler $F^{(val)}$ mit dem CNN reproduziert. Die Generalisierungseigenschaften von CNN(s, Pat A, M) waren mit mittleren Approximationsfehlern von $F_M^{(val)} = 30,3\%$ für die Zeitreihen von Patient B und $F_M^{(val)} = 21,1\%$ für die Zeitreihen von Patient C eher schlecht.

CNN(s, Pat B, M), welches anhand von Zeitreihen optimiert wurde, die an verschiedenen Elektrodenkombinationen von Patient B aufgezeichnet wurden, wies für Patient B einen durchschnittlichen Approximationsfehler von $F_M^{(val)} = 14,1\%$

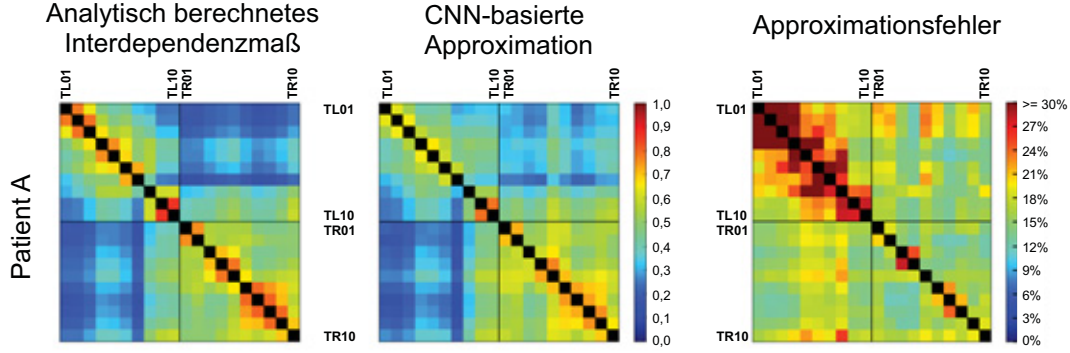


Abbildung 6.13: Über den analysierten Datensatz gemitteltes analytisch berechnetes Interdependenzmaß $N_{s,(mean)}$ (links) und Approximation $N_{s,(mean)}^{(CNN)}$ (Mitte) mit CNN(s, Pat A, M) für die Zeitreihen aller Elektrodenkombinationen von Patient A. Rechts Approximationsfehler $F^{(val)}$.

auf. Dabei zeigte sich wiederum eine gute Approximation für Zeitreihen, die in entfernt gelegenen Hirnstrukturen aufgezeichnet wurden (insbesondere alle interhemisphärischen Elektrodenkombinationen, siehe auch Abbildung 6.14). Die CNN-basierte Approximation der Interaktionsstärke zwischen Hirnstrukturen, deren Aktivität an räumlich benachbarten Elektroden aufgezeichnet wurde, wies vergleichsweise hohe Fehler von teilweise $F^{(val)} > 30\%$ auf, da die kurzfristigen Fluktuationen mit dem CNN nicht reproduziert werden konnten. Dennoch zeigte die mit CNN(s, Pat B, M) erhaltene über den Validierungsdatsatz gemittelte Approximation $N_{s,(mean)}^{(CNN)}$ ähnliche Werte wie das analytisch berechnete Interdependenzmaß $N_{s,(mean)}$. So wiesen die Zeitreihen der Elektrodenkombinationen der fokalen Hemisphäre auch bei diesem Patienten eine erhöhte Interaktionsstärke auf, was mit dem CNN sehr gut reproduziert wurde. Ebenfalls waren in der linken Hemisphäre zwei Strukturen im Bereich der Elektroden TL01 bis TL04 (Amygdala) sowie TL05 bis TL10 (Hippocampus) durch eine jeweils erhöhte intrastrukturelle Interaktionsstärke verglichen mit den übrigen Hirnregionen der linken Hemisphäre zu erkennen. Trotz der vergleichsweise hohen Approximationsfehler in diesen Bereichen, konnte auch dieser Effekt mit dem CNN reproduziert werden. Die Generalisierungseigenschaften von CNN(s, Pat B, M) für die SEEG-Zeitserien der Patienten A und C waren mit durchschnittlichen Approximationsfehlern für alle Elektrodenkombinationen von $F_M^{(val)} = 25,5\%$ bzw. $F_M^{(val)} = 19,2\%$ eher schlecht.

Mit CNN(s, Pat C, M), welches anhand von Zeitreihen verschiedener Elektrodenkombinationen von Patient C optimiert wurde, konnte ein CNN bestimmt werden, welches für die SEEG-Zeitserien aller drei untersuchten Patienten sehr gute

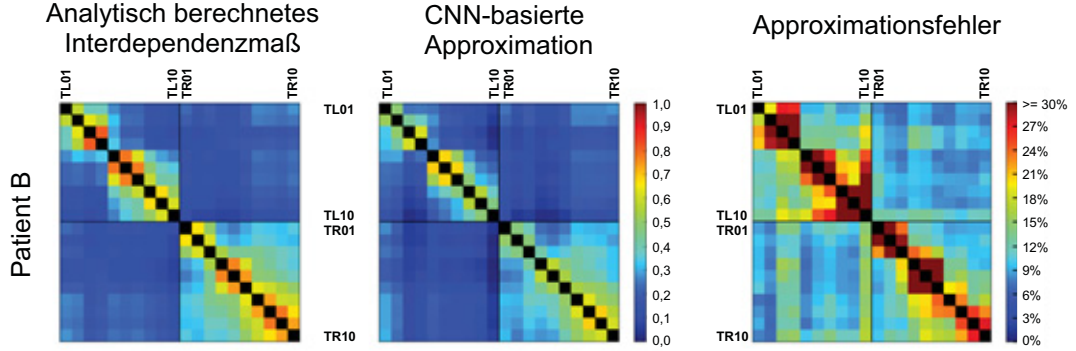


Abbildung 6.14: Wie Abbildung 6.13, nur für CNN(s, Pat B, M) und Zeitreihen von Patient B.

Approximationsgüten bot. Für Patient C betrug der durchschnittliche Approximationsfehler aller Elektrodenkombinationen lediglich $F_M^{(val)} = 10,6\%$ (siehe auch Abbildung 6.15). Es ist zu erkennen, daß die Interaktionsstärke sowohl zwischen räumlich benachbarten als auch zwischen entfernt gelegenen Hirnstrukturen mit CNN(s, Pat C, M) mit hoher Güte geschätzt werden konnte. Durch die Trainingsmenge mit Zeitreihen, die in unterschiedlichen Hirnregionen aufgezeichnet wurden, trat keine Adaption an die Interaktion zwischen zwei bestimmten Strukturen auf. Lediglich für die Zeitreihen der Elektrode TL08 wurde eine außergewöhnlich hohe Abweichung festgestellt. Dies konnte auf Netzbrummen zurückgeführt werden, welches zeitweise in den Aufzeichnungen dieser Elektrode auftrat. Wiederum konnte die innerhalb der fokalen Hemisphäre erhöhte Interaktionsstärke mit dem analytisch berechneten Interdependenzmaß $N_{s,(mean)}$ nachgewiesen und mit der CNN-basierten Approximation $N_{s,(mean)}^{(CNN)}$ reproduziert werden.

Auch für die analysierten Datensätze der Patienten A und B, deren Zeitreihen nicht zur Optimierung benutzt wurden, zeigte CNN(s, Pat C, M) sehr kleine Approximationsfehler für alle Elektrodenkombinationen von durchschnittlich $F_M^{(val)} = 11,4\%$ bzw. $F_M^{(val)} = 10,2\%$ (siehe auch Abbildung 6.15). Dabei konnte für beide Patienten die Interaktionsstärke für alle Hirnstrukturen gleichermaßen gut mit CNN(s, Pat C, M) geschätzt werden. Exemplarisch sind in Abbildung 6.16 ein Ausschnitt des zeitlichen Verlaufs von analytisch berechnetem Interdependenzmaß sowie CNN-basierter Approximation für die Zeitreihen der Elektrodenkombination TR10-TL02 von Patient A sowie der Elektrodenkombination TL09-TL01 von Patient B gezeigt.

Durch eine Optimierung mit SEEG-Zeitreihen, die an verschiedenen Elektrodenkombinationen von den Patienten A, B und C aufgezeichnet wurden, war es möglich,

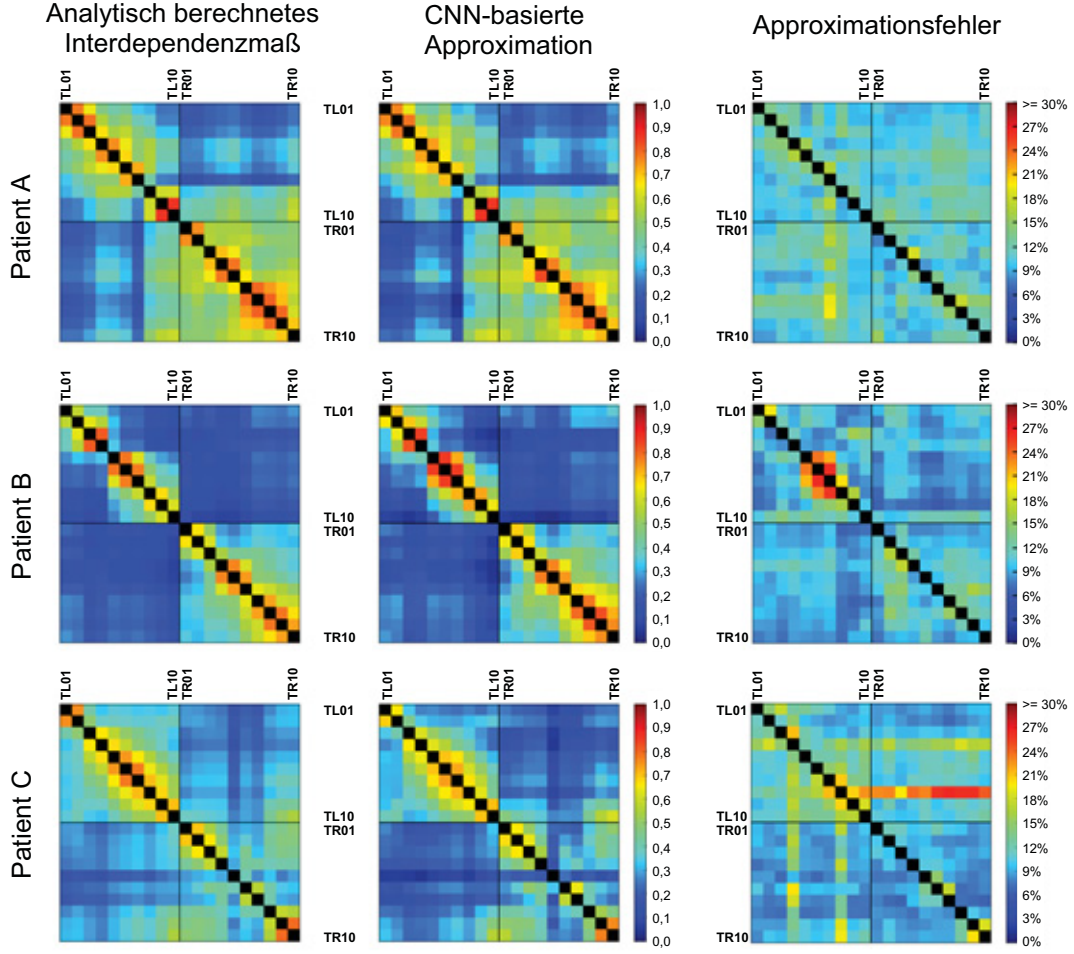


Abbildung 6.15: Wie Abbildung 6.13, nur für CNN(s, Pat C, M) und Zeitreihen der Patienten A, B und C.

ein CNN zu bestimmen (CNN(s, M, M)), welches für alle drei Patienten eine sehr hohe Approximationsgüte für alle Hirnstrukturen erreichte (siehe Abbildung 6.17). Dies bezog sich einerseits auf die kurz- und langfristigen Fluktuationen, wie an den geringen Approximationsfehlern $F_M^{(val)}$ abzulesen war, sowie auf das mittlere geschätzte Interdependenzmaß $N_{s,(mean)}^{(CNN)}$ der jeweils für die Patienten analysierten Datensätze. Hier konnten die Effekte der erhöhten Interaktionsstärke innerhalb der fokalen Hemisphäre oder der erhöhten Interaktionsstärke innerhalb funktionell unterschiedlicher Hirnstrukturen (Amygdala, Hippocampus), welche das analytisch berechnete Interdependenzmaß $N_{s,(mean)}$ zeigte, mit dem CNN sehr gut reproduziert werden.




Abbildung 6.16: Zeitlicher Verlauf des analytisch berechneten Interdependenzmaßes sowie der Approximation mit CNN(s, Pat C, M) für eine etwa 18 Stunden dauernde SEEG-Aufzeichnung der Elektrodenkombination TR10-TL02 von Patient A (oben) und für eine etwa 16 Stunden dauernde SEEG-Aufzeichnung der Elektrodenkombination TL09-TL01 von Patient B (unten); rote Markierungen entsprechen elektrischem Anfallsbeginn.

Bisher konnte gezeigt werden, daß durch Optimierungen anhand von SEEG-Zeitreihen einzelner Elektrodenkombinationen für verschiedene Hirnstrukturen CNN gefunden werden können, die die Interaktionsstärke zwischen diesen schätzen können. Da dies für intrahemisphärische, interhemisphärische, intrastrukturelle sowie interstrukturelle Elektrodenkombinationen nachgewiesen werden konnte, liegt die Vermutung nahe, daß für beliebige Hirnstrukturen CNN zur Schätzung der Interaktionsstärke bestimmt werden können. Dieser Verdacht wurde ebenfalls durch die Ergebnisse der Untersuchung der Generalisierungseigenschaften erhärtet. Hier konnten sowohl durch eine Optimierung anhand von SEEG-Zeitreihen verschiedener Hirnstrukturen eines Patienten sowie durch eine Optimierung anhand von SEEG-Zeitreihen verschiedener Patienten CNN gefunden werden, die die Interaktionsstärke zwischen verschiedenen Hirnstrukturen für verschiedene Patienten schätzen konnten. Dabei wurden möglicherweise auf die Epilepsie zurückzuführende räumlich ausgeprägte physiologische Effekte von den jeweiligen CNN reproduziert. Dies könnte bedeuten, daß eventuell auch zeitlich ausgeprägte Variationen der Interaktionsstärke mit Hilfe von CNN in dem Sinne detektiert werden können, daß

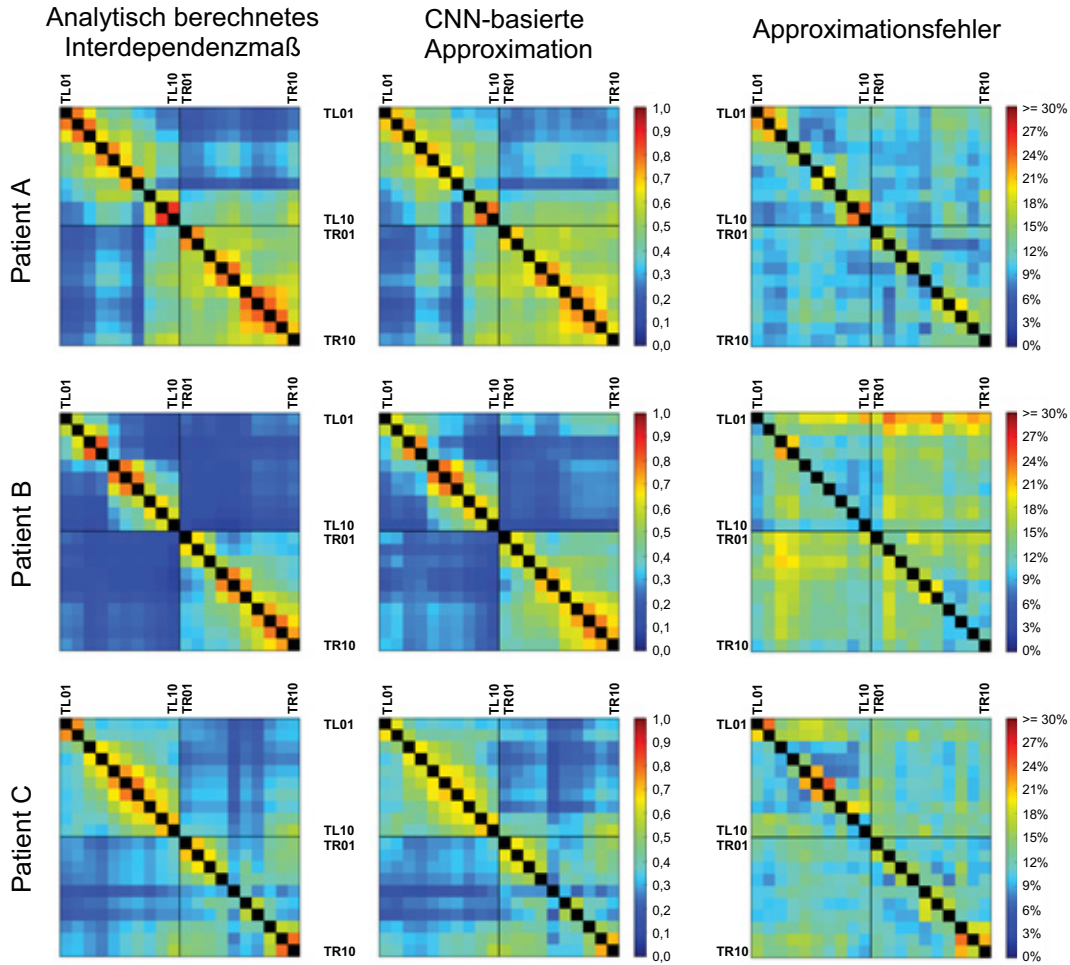


Abbildung 6.17: Wie Abbildung 6.13, nur für CNN(s, M, M) und Zeitreihen der Patienten A, B und C.

dies zum Nachweis eines Voranfallszustands genutzt werden kann. Dies wird im nächsten Abschnitt anhand eines zuvor optimierten CNN überprüft.

6.7.3 Prädiktive Merkmale

Der zweifelsfreie Nachweis eines Voranfallszustandes anhand der zeitlichen Entwicklung eines Synchronisationsmaßes ist sehr schwierig. Zum einen wäre ein solcher Zustand durch eine Vielzahl dynamischer Hirnzustände überlagert, wodurch die Isolierung charakteristischer Eigenschaften in EEG-Aufzeichnungen entsprechend schwer ist. Hier existiert zusätzlich das Problem, daß keine Referenzaufzeichnungen

von gesunden Probanden zur Verfügung stehen, da die Implantation von Elektroden ein gewisses Risiko birgt. Hinzu kommt, daß die EEG-Aufzeichnungen im Rahmen der prächirurgischen Abklärung von Epilepsiepatienten meist nur einige Tage dauern und somit - abhängig vom Patienten - in der Regel nur wenige epileptische Anfälle enthalten. Durch die hohe Anzahl von Elektrodenkombinationen ist dann ein gewisser Anteil scheinbar prädiktiver Strukturen aus rein statistischen Gründen zu erwarten. Viele Studien der letzten Jahre beschäftigten sich daher eher mit der Fragestellung, wie ein Voranfallszustand statistisch signifikant nachgewiesen werden kann [AMK⁺03, AKS⁺03, KAM⁺04, MKR⁺05, SWM⁺06, ACEM09]. Bei der im folgenden durchgeführten Untersuchung lag der Schwerpunkt demnach nicht auf der zweifelsfreien Identifizierung eines Voranfallszustandes, sondern vielmehr darauf, ob die zeitlichen Variationen des analytisch berechneten Interdependenzmaßes durch die CNN-basierte Approximation erhalten blieben.

Dazu wurde eine retrospektive Analyse unter der Annahme der Existenz eines Voranfallszustandes mit einer Dauer von 240 Minuten vor einem Anfall [MLDE00, MAK⁺03, MKA⁺03] durchgeführt. Aktuelle Methoden zum Nachweis eines solchen Voranfallszustandes basieren auf der Annahme einer verringerten oder erhöhten Interaktionsstärke innerhalb dieses präiktalen Intervalls verglichen mit der Interaktionsstärke des interiktalen Intervalls, also der übrigen anfallsfreien Zeit¹⁰. Daher wurden im folgenden die relativen Häufigkeiten der Werte des analytisch berechneten Interdependenzmaßes N_s sowie der CNN-basierten Approximation $N_s^{(CNN)}$ im präiktalen sowie interiktalen Intervall bestimmt. Exemplarisch wurde dies am Beispiel von CNN(s, Pat C, M) durchgeführt. Dabei wurden die gleichen SEEG-Aufzeichnungen analysiert, wie in Abschnitt 6.7.2 (Patient A: 18 Stunden, Patient B: 16 Stunden, Patient C: 12 Stunden, jeweils ein Anfall innerhalb der Aufzeichnung).

In Abbildung 6.18 sind die relativen Häufigkeiten von analytisch berechnetem Interdependenzmaß sowie CNN-basierter Approximation für Zeitreihen aus dem interiktalen und präiktalen Intervall der Zeitreihen von Elektrodenkombination TR01-TR10 von Patient C dargestellt. Es ist zu erkennen, daß N_s im präiktalen Intervall im Mittel höhere Werte annahm als im interiktalen. Aufgrund des Approximationsfehlers von $F_{(TR01-TR10)}^{(val)} = 8,9\%$ trat eine leichte Verbreiterung der Verteilungen der mit CNN(s, Pat C, M) geschätzten Interdependenzen für die Zeitreihen aus präiktalem und interiktalem Intervall auf. Dennoch blieb die Tendenz zu höheren Werten für Zeitreihen aus dem präiktalen Intervall bei der CNN-basierten Approximation erhalten.

¹⁰Um anfallsbezogene Aktivität auszuschließen, wurden SEEG-Zeitreihen, die während eines Anfalls und innerhalb von 30 Minuten nach einem Anfall aufgezeichnet wurden, verworfen.




Abbildung 6.18: Relative Häufigkeiten des analytisch berechneten Interdependenzmaßes (links) und der CNN-basierten Approximation (rechts) für Zeitreihen der Elektrodenkombination TR01-TR10 aus dem interiktalen und präiktalen Intervall von Patient C; Histogramm mit Klassengröße 0,02.

In Abbildung 6.19 sind die jeweiligen Verteilungen für die Zeitreihen der Elektrodenkombination TR09-TL08 von Patient C gezeigt. Es ist zu erkennen, daß das analytisch berechnete Interdependenzmaß für Zeitreihen aus dem präiktalen Intervall im Mittel höhere Werte annahm. Für die CNN-basierte Approximation war der umgekehrte Effekt zu beobachten. Mit $\text{CNN}(s, \text{Pat C}, M)$ erfolgte für diese Elektrodenkombination demnach eine Unterschätzung der Interaktionsstärke für Zeitreihen aus dem präiktalen Intervall, was sich auch im vergleichsweise hohen Approximationsfehler von $F_{(\text{TR09-TL08})}^{(val)} = 15,5\%$ widerspiegelte.

In Abbildung 6.20 sind die jeweiligen Verteilungen für die Zeitreihen der Elektrodenkombination TR02-TR10 von Patient A gezeigt. Es ist zu erkennen, daß es mit $\text{CNN}(s, \text{Pat C}, M)$ aufgrund des Approximationsfehlers von $F_{(\text{TR02-TR10})}^{(val)} = 10\%$ zu einer Verbreiterung der Verteilungen der Werte des Interdependenzmaßes für Zeitreihen aus dem interiktalen und präiktalen Intervall kam. Dennoch blieb die Tendenz zu niedrigeren Interaktionsstärken für Zeitreihen aus dem präiktalen Intervall erhalten, obwohl die Daten von Patient A nicht zur Optimierung von $\text{CNN}(s, \text{Pat C}, M)$ genutzt wurden.




Abbildung 6.19: Wie Abbildung 6.18 nur für Zeitreihen der Elektrodenkombination TR09-TL08 von Patient C.




Abbildung 6.20: Wie Abbildung 6.18 nur für Zeitreihen der Elektrodenkombination TR02-TR10 von Patient A.




Abbildung 6.21: Wie Abbildung 6.18 nur für Zeitreihen der Elektrodenkombination TR05-TL02 von Patient B.

In Abbildung 6.21 sind die jeweiligen Verteilungen der Elektrodenkombination TR05-TL02 von Patient B gezeigt. Auch hier wurden für Zeitreihen eines Patienten, dessen Daten nicht zur Optimierung von CNN(s, Pat C, M) genutzt wurden, die im Mittel höheren Werte des analytisch berechneten Interdependenzmaßes für Zeitreihen aus dem präiktalen Intervall mit CNN(s, Pat C, M) reproduziert (Approximationsfehler $F_{(TL04-TL05)}^{(val)} = 8,5\%$).

Es konnte nachgewiesen werden, daß CNN in der Lage sind, die mit dem analytisch berechneten Interdependenzmaß nachweisbaren präiktalen Veränderungen zu reproduzieren und somit prädiktive Merkmale im Sinne von Änderungen der Interaktionsstärke während eines hypothetischen Voranfallszustandes zu detektieren. Die Approximationsfehler waren dabei gering genug, um die durch das analytisch berechnete Interdependenzmaß erhaltene Trennbarkeit zwischen interiktalen und präiktalen Verteilungen zu erhalten. Um epileptische Anfälle zuverlässig vorherzusagen zu können, müssten allerdings in Zukunft zunächst geeignete prospektive Algorithmen entwickelt werden. Wie in den gezeigten Abbildungen zu erkennen ist, müsste für eine zuverlässige Anfallsvorhersage ebenso die Sensitivität und Spezifität der verwendeten Algorithmen weiter verbessert werden. Eine Diskussion dieser Problematik findet sich in der Zusammenfassung der Dissertation.

6.7.4 Diskussion

In den durchgeführten Untersuchungen konnte erstmals nachgewiesen werden, daß es mit CNN möglich ist, anhand von SEEG-Zeitreihen, die in unterschiedlichen Hirnstrukturen aufgezeichnet wurden, die Interaktionsstärke zwischen ihnen zu schätzen. Es konnte ebenfalls gezeigt werden, daß diese CNN, welche anhand von Zeitreihen einzelner Elektrodenkombinationen optimiert wurden, bereits gewisse Generalisierungseigenschaften besaßen. Diese bezogen sich teilweise nur auf andere Hirnstrukturen des Patienten, dessen Zeitreihen zur Optimierung genutzt wurden, und in einem Fall sogar auf einen anderen Patienten. Es zeigte sich jedoch, daß - abhängig von der Elektrodenkombination, von der die Zeitreihen für die Trainingsmenge stammten - eine Schätzung der Interaktionsstärke nur für räumlich benachbarte oder entfernt gelegene Hirnstrukturen zuverlässig möglich war. Dieser Effekt konnte erfolgreich durch Optimierungen mit Zeitreihen von verschiedenen Elektrodenkombinationen einzelner Patienten verhindert werden. Somit konnte erstmals ein CNN bestimmt werden, das unabhängig von der Hirnstruktur und unabhängig vom untersuchten Patienten eine zuverlässige Schätzung der Interaktionsstärke zuließ. Durch Optimierungen mit Zeitreihen, die an unterschiedlichen Elektroden in verschiedenen Patienten gemessen wurden, war es ebenfalls möglich, ein CNN zu finden, welches für alle untersuchten Patienten eine Schätzung der Interaktionsstärke zwischen beliebigen Hirnstrukturen bot. Der Nachweis, daß diese CNN universell einsetzbare sind, welche die Interaktionsstärke auch für weitere Patienten zuverlässig schätzen, müsste in weiteren Untersuchungen an einem größeren Patientenkollektiv erbracht werden. In diesem Zusammenhang wiesen weder die durch Optimierungen mit Zeitreihen einzelner Elektrodenkombinationen oder verschiedener Elektrodenkombinationen gefundenen CNN Gemeinsamkeiten bei ihren Templates auf (siehe Anhang B). Hier konnten demnach keine weiteren Hinweise auf ein universelles CNN gefunden werden. Abschließend wurde gezeigt, daß CNN trotz der auftretenden Approximationsfehler in der Lage waren, die Variationen der Interaktionsstärke bezüglich eines hypothetischen Voranfallszustandes zu reproduzieren.

6.8 Charakterisierung der Richtung von Interaktionen in Zeitreihen hirnelektrischer Aktivität

Wie in der Einleitung dieses Kapitels bereits erwähnt, haben verschiedene Konzepte in den letzten Jahren die Detektion von Driver-Responder-Abhängigkeiten zwischen dynamischen Systemen ermöglicht. Nach der erfolgreichen Detektion der

Kopplungsrichtung anhand der Zeitreihen von strukturell ähnlichen und strukturell unterschiedlichen Modellsystemen mit CNN in Kapitel 5 wurde untersucht, ob dies ebenfalls für SEEG-Zeitreihen möglich ist. Dazu wurden zunächst Zeitreihen einzelner Elektrodenkombinationen für eine Optimierung und die anschließende Validierung genutzt. Motiviert durch die Ergebnisse der Untersuchungen der Generalisierungseigenschaften in Abschnitt 6.7 wurden anschließend Optimierungen mit Zeitreihen verschiedener Elektrodenkombinationen einzelner und verschiedener Patienten durchgeführt. Hier wurde überprüft, ob mit CNN, die Interaktionsrichtung zwischen verschiedenen Hirnstrukturen ohne eine spezifische Optimierung detektiert werden kann.

Wie bereits erwähnt, bieten die vorgestellten nichtlinearen Interdependenzmaße die Möglichkeit der Detektion einer Kopplungsrichtung (siehe Gleichung 2.30). Da in [AGLE99, QKKG02] Hinweise gefunden wurden, daß es insbesondere mit S_a möglich ist, asymmetrische Kopplungen in EEG-Aufzeichnungen zu detektieren, wurden sämtliche Untersuchungen mit diesem Maß durchgeführt. Als Datenbasis dienten Zeitreihen der bereits in Abschnitt 6.7 vorgestellten Patienten A und B. Auf eine Untersuchung der Daten von Patient C wurde verzichtet, da dieser in Abschnitt 6.7 insgesamt die besten Ergebnisse zeigte, es jedoch auch Ziel der vorliegenden Arbeit war, die Grenzen des Verfahrens zu überprüfen.

Bei der Nennung der Elektrodenkombinationen gilt im folgenden die Konvention, daß die erste genannte Elektrode bei der analytischen Berechnung der nichtlinearen Interdependenzmaße System X entspricht und die zweite System Y . Für die CNN-basierte Approximation wurden die Zeitreihen der zuerst genannten Elektrode den Eingängen der CNN-Zellen zugewiesen und die Zeitreihen der als zweites genannten dem Anfangszustand. Die Templates sämtlicher im folgenden gezeigten CNN sind in Anhang B aufgelistet.

6.8.1 Optimierung und Validierung mit Zeitreihen einzelner Elektrodenkombinationen individueller Patienten

Im folgenden wurde untersucht, ob CNN in der Lage sind, die Interaktionsrichtung zwischen verschiedenen Hirnstrukturen zu detektieren. Daher wurden für die Optimierung der CNN für die Patienten A und B jeweils SEEG-Aufzeichnungen von intrahemisphärischen sowie interhemisphärischen Elektrodenkombinationen verwendet. So wurden für Patient A mit TL01-TL06 eine intrahemisphärische Elektrodenkombination der kontralateralen Hemisphäre, mit TL07-TR05 eine interhemisphärische Elektrodenkombination der fokalen Hemisphäre (TR05 im epilepti-

schen Fokus) sowie mit TR03-TR08 eine Elektrodenkombination, bei der beide Elektroden im epileptischen Fokus lagen, untersucht. Nach den gleichen Kriterien wurden bei Patient B die Elektrodenkombinationen TL03-TL10 (kontralaterale Hemisphäre), TL09-TR04 (interhemisphärisch mit TR04 im epileptischen Fokus) und TR04-TR08 (fokale Hemisphäre, beide Elektroden im epileptischen Fokus) ausgewählt. Die Ergebnisse der Validierungen der CNN, welche jeweils bestimmt werden konnten, sind in Tabelle 6.7 aufgelistet. Die Validierungen wurden dabei für Patient A mit SEEG-Aufzeichnungen von ca. 116 Stunden Dauer und für Patient B mit SEEG-Aufzeichnungen von etwa 50 Stunden Dauer durchgeführt.

CNN	Pat.	Validierung Elektrodenkomb.	Approximations- fehler $F^{(val)}$
CNN(a, Pat A, TL01-TL06)	A	TL01-TL06	15,6%
CNN(a, Pat A, TL07-TR05)	A	TL07-TR05	10,9%
CNN(a, Pat A, TR03-TR08)	A	TR03-TR08	58,7%
CNN(a, Pat B, TL03-TL10)	B	TL03-TL10	12,1%
CNN(a, Pat B, TL09-TR04)	B	TL09-TR04	18,8%
CNN(a, Pat B, TR04-TR08)	B	TR04-TR08	36,2%

Tabelle 6.7: CNN, die in den Optimierungen mit Zeitreihen einzelner Elektrodenkombinationen bestimmt werden konnten. Approximationsfehler (rechts) für die Zeitreihen der angegebenen Elektrodenkombination des jeweiligen Patienten (Mitte).

Für Patient A konnte mit CNN(a, Pat A, TL07-TR05) ein CNN gefunden werden, welches einen Approximationsfehler von lediglich $F_{(TL07-TR05)}^{(val)} = 10,9\%$ aufwies. In Abbildung 6.22 sind das analytisch berechnete Interdependenzmaße und die CNN-basierte Approximation gezeigt. Es ist zu erkennen, daß das CNN die kurz- und langfristigen Fluktuationen der Interaktionsrichtung mit hoher Güte reproduzieren konnte. Somit war eine Schätzung der Interaktionsrichtung zwischen Hirnstrukturen beider Hemisphären von Patient A möglich. Dabei war zu beachten, daß die Elektrode TR05 im epileptischen Fokus lag und somit das CNN ebenfalls für dessen pathologisch veränderte Dynamik eine Interaktionsrichtung schätzen konnte.

Ebenfalls konnte mit CNN(a, Pat A, TL01-TL06) für die intrahemisphärische Elektrodenkombination TL01-TL06 der kontralateralen Hemisphäre von Patient A ein CNN gefunden werden, welches eine gute Approximation (Approximationsfehler $F_{(TL01-TL06)}^{(val)} = 15,6\%$) des analytisch berechneten Interdependenzmaßes und somit eine Schätzung der Interaktionsrichtung bot. Im Gegensatz dazu konnte für

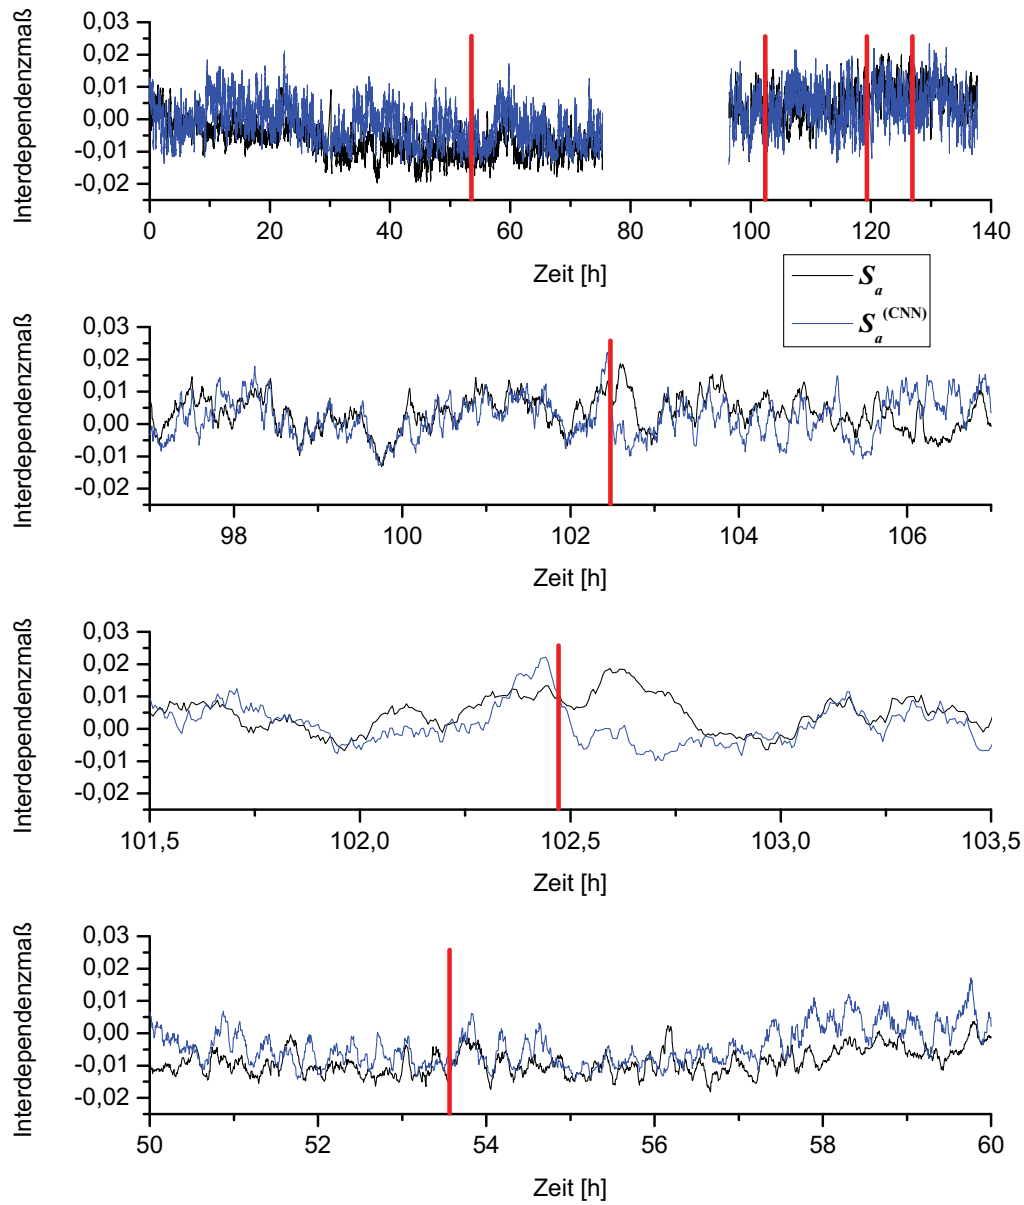


Abbildung 6.22: Oben: Zeitlicher Verlauf des analytisch berechneten Interdependenzmaßes sowie der Approximation mit CNN(a, Pat A, TL07-TR05) für eine etwa 116 Stunden dauernde SEEG-Aufzeichnung (Elektrodenkombination TL07-TR05 von Patient A), darunter Ausschnitte. Rote Markierungen entsprechen elektrischem Anfallsbeginn. Größere Aufzeichnungslücke nach 75 Stunden. Ein positiver Wert bedeutet, daß die von Elektrode TL07 abgetastete Hirnstruktur die von Elektrode TR05 abgetastete Hirnstruktur treibt bzw. umgekehrt für negative Werte.

die Elektrodenkombination TR03-TR08 (beide Elektroden zeichneten die Aktivität des epileptischen Fokus auf) kein CNN gefunden werden, welches eine ausreichende Approximationsgenauigkeit bot ($F_{(TR03-TR08)}^{(val)} = 58,7\%$ für CNN(a, Pat A, TR03-TR08)). Das CNN zeigte dabei eine generelle Tendenz zu niedrigen Zellausgaben $v = -1$ unabhängig von den verarbeiteten SEEG-Zeitreihen. Somit konnte dieses CNN für die Dynamik innerhalb des epileptischen Fokus keine Interaktionsrichtung schätzen. Dies könnte damit zusammenhängen, daß innerhalb der Hirnstrukturen des epileptischen Fokus, der als eine funktionelle Einheit aufgefasst werden kann, eine erhöhte Interaktionsstärke auftrat. Dies erschwerte die Detektion einer Interaktionsrichtung, wie in Abschnitt 2.6 bereits diskutiert wurde.

Für Patient B zeigte sich ein ähnliches Bild. Für die intrahemisphärische Elektrodenkombination TL03-TL10 der kontralateralen Hemisphäre sowie die interhemisphärische Elektrodenkombination TL09-TR04 (TR04 im epileptischen Fokus) konnten CNN gefunden werden, die einen Approximationsfehler $F^{(val)} < 20\%$ aufwiesen. In Abbildung 6.23 ist das analytisch berechnete Interdependenzmaß sowie die CNN-basierte Approximation mit CNN(a, Pat B, TL03-TL10) dargestellt. Es ist zu erkennen, daß das CNN sowohl lang- als auch kurzfristige Fluktuationen der asymmetrischen Interaktion mit hoher Güte reproduzieren konnte. Lediglich im Zeitraum zwischen 20 und 35 Stunden zeigte sich eine leichte Überschätzung des Einflusses der Hirnstruktur, die von Elektrode TL10 aufgezeichnet wurde auf die Hirnstruktur, die von Elektrode TL03 aufgezeichnet wurde. Dies konnte darauf zurückgeführt werden, daß das CNN während des Optimierungsverfahrens nur die Detektion starker asymmetrischer Interaktionen erlernt hatte.

In Abbildung 6.24 sind das analytisch berechnete Interdependenzmaß sowie die CNN-basierte Approximation mit CNN(a, Pat B, TL09-TR04) gezeigt. Es ist zu erkennen, daß kurzfristige Änderungen der asymmetrischen Interaktion meist gut vom CNN reproduziert wurden (siehe mittleren und unteren Ausschnitt). Während das analytisch berechnete Interdependenzmaß, über den gesamten Zeitraum betrachtet, meist die mit Elektrode TL09 abgetastete Hirnstruktur als Treiber detektierte, war ein generell niedrigeres Niveau bei der CNN-basierten Approximation zu erkennen. Dies führte einerseits zu einer Unterschätzung des Einflusses der Hirnstruktur um Elektrode TL09 auf die Hirnstruktur um Elektrode TR04 und teilweise zur Detektion einer umgekehrten Interaktionsrichtung. Dies konnte darauf zurückgeführt werden, daß CNN(a, Pat B, TL09-TR04) bevorzugt Zellausgaben von $v = -1$ annahm und somit eine Tendenz zu niedrigeren Werten der Kenngröße zeigte.

Auch für Patient B konnte für die Elektrodenkombination, welche die Aktivität des epileptischen Fokus aufgezeichnet hat, kein CNN mit einer zuverlässigen Approxi-

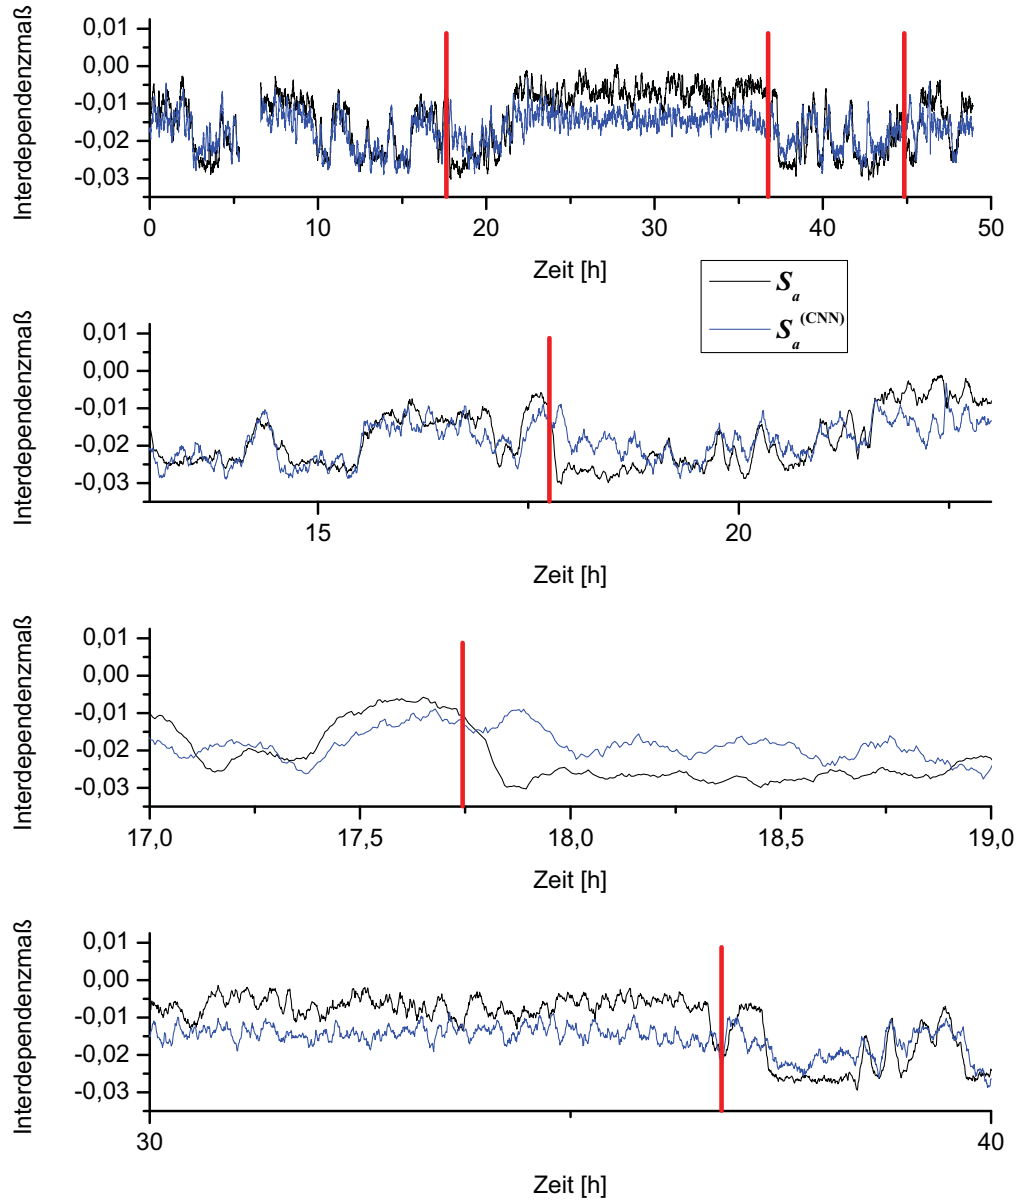


Abbildung 6.23: Oben: Zeitlicher Verlauf des analytisch berechneten Interdependenzmaßes sowie der Approximation mit CNN(a, Pat B, TL03-TL10) für eine etwa 50 Stunden dauernde SEEG-Aufzeichnung (Elektrodenkombination TL03-TL10 von Patient B), darunter Ausschnitte. Rote Markierungen entsprechen elektrischem Anfallsbeginn. Aufzeichnungslücke nach etwa 5 Stunden.

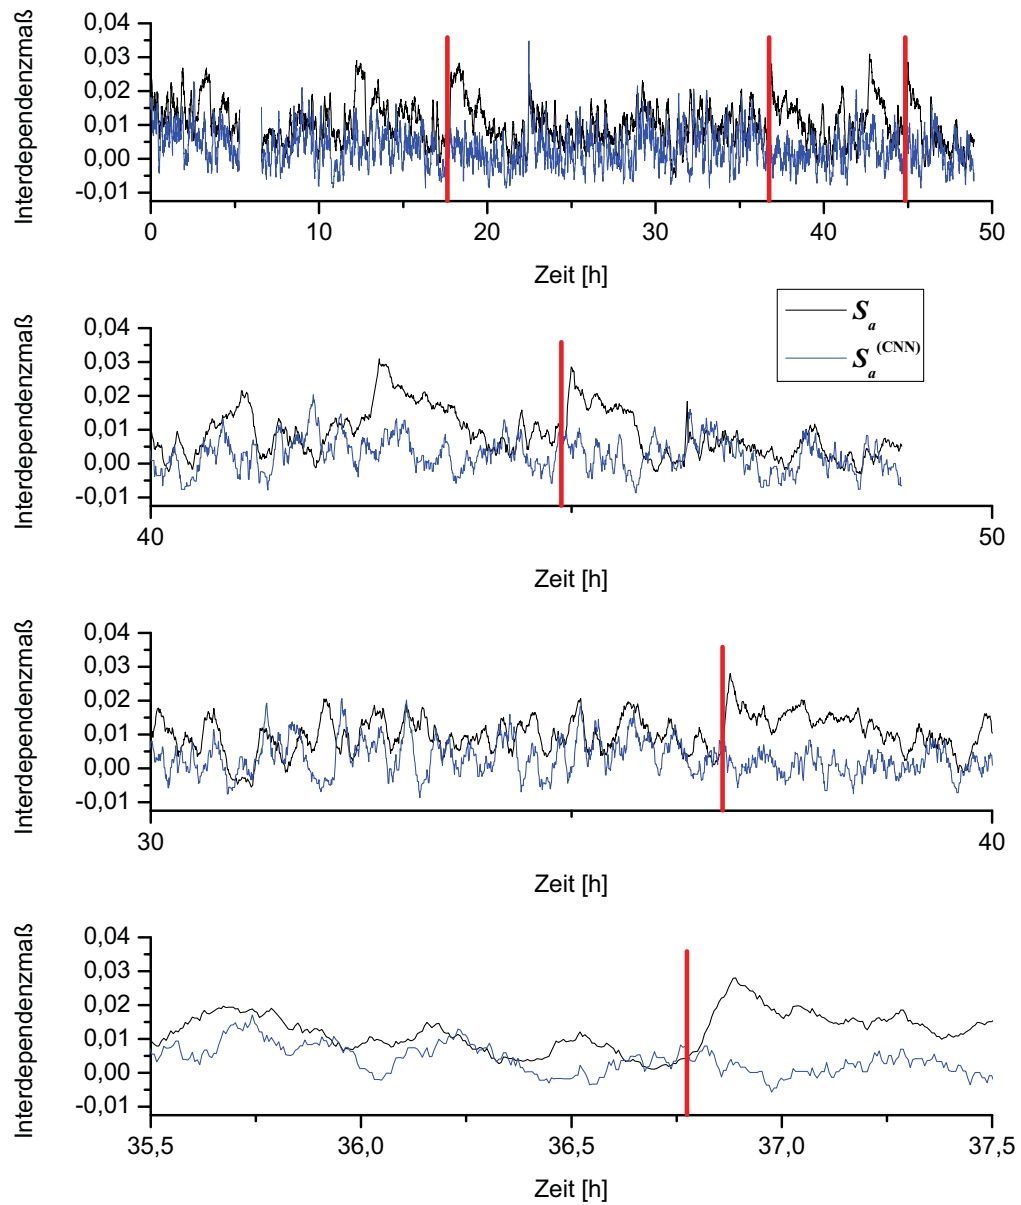


Abbildung 6.24: Wie Abbildung 6.23, jedoch für CNN(a, Pat B, TL09-TR04) und Zeitreihen der Elektrodenkombination TL09-TR04 von Patient B.

mation des analytisch berechneten Interdependenzmaßes gefunden werden (Approximationsfehler $F_{(TR04-TR08)}^{(val)} = 36,2\%$ mit CNN(a, Pat B, TR04-TR08)). Auch hier könnte dies an der erhöhten Interaktionsstärke innerhalb der Hirnstrukturen des epileptischen Fokus liegen, die eine Detektion einer Interaktionsrichtung erschwerte.

Es konnte nachgewiesen werden, daß CNN in der Lage sind, durch Optimierungen mit Zeitreihen einzelner Elektrodenkombinationen, die Interaktionsrichtung zwischen verschiedenen Hirnstrukturen anhand ihrer Zeitreihen hirnelektrischer Aktivität zu detektieren. Dies konnte für intrahemisphärische sowie für interhemisphärische Interaktionen gezeigt werden. Dabei konnte auch die Interaktion zwischen dem epileptischen Fokus und anderen Hirnstrukturen mit CNN geschätzt werden. Lediglich die Charakterisierung der Richtung der Interaktion innerhalb des epileptischen Fokus konnte nicht mit CNN erfolgen. Dies könnte eine Folge der fokal erhöhten Interaktionsstärke sein, wie sie in Abschnitt 6.7 beobachtet wurde.

Die Templates der hier gefundenen CNN (siehe Anhang B) wiesen keine Gemeinsamkeiten etwa beim Betrag oder den Vorzeichen der Koeffizienten auf. Somit konnten hier keine Hinweise auf ein universelles CNN gefunden werden.

6.8.2 Generalisierungseigenschaften

Im folgenden wurde untersucht, welche Generalisierungseigenschaften die zuvor bestimmten CNN besaßen. Dahinter stand genau wie in Abschnitt 6.7.2 die Fragestellung, inwieweit diese mit Zeitreihen einzelner Elektrodenkombinationen - d.h. einzelner Hirnstrukturen - optimierten CNN auch die Interaktionsrichtung zwischen verschiedenen Hirnstrukturen eventuell sogar verschiedener Patienten schätzen konnten.

Daher wurden die CNN mit den geringsten Approximationsfehlern je Patient (CNN(a, Pat A, TL07-TR05) und CNN(a, Pat B, TL03-TL10)) anhand der Zeitreihen aller Elektrodenkombinationen beider Patienten A und B validiert. Wie bereits in Abschnitt 6.7.2 wurde auch hier die Dauer der Datensätze, die zur Validierung genutzt wurden, reduziert, da die benötigte Rechenzeit durch die Berechnung aller Elektrodenkombinationen um den Faktor 380 anstieg. Es wurden dabei die gleichen SEEG-Aufzeichnungen wie in Abschnitt 6.7.2 verwendet (18 Stunden Dauer für Patient A, 16 Stunden Dauer für Patient B, jeweils 1 Anfall aufgezeichnet). Die Ergebnisse der Validierungen sind in Tabelle 6.8 aufgelistet.

CNN	Pat.	Validierung Elektrodenkomb.	Approximations- fehler $F_M^{(val)}$
CNN(a, Pat A, TL07-TR05)	A	alle	20,1%
CNN(a, Pat A, TL07-TR05)	B	alle	20,3%
CNN(a, Pat B, TL03-TL10)	A	alle	24,6%
CNN(a, Pat B, TL03-TL10)	B	alle	17,7%

Tabelle 6.8: CNN, die in den Optimierungen mit Zeitreihen einzelner Elektrodenkombinationen bestimmt werden konnten. Über alle Elektrodenkombinationen gemittelter Approximationsfehler (rechts) für die Zeitreihen des jeweiligen Patienten (Mitte).

Die Approximationsfehler sowie die über den analysierten Datensatz gemittelten Werte des analytisch berechneten Interdependenzmaßes $S_{a,(mean)}$ und der Approximation $S_{a,(mean)}^{(CNN)}$ mit CNN(a, Pat A, TL07-TR05) sind in Abbildung 6.25 gezeigt. Die CNN-basierte Approximation zeigte einen Fehler von durchschnittlich $F_M^{(val)} = 20,1\%$ für die Daten des Patienten, mit dessen Zeitreihen das CNN trainiert wurde. Für Patient B betrug der Approximationsfehler $F_M^{(val)} = 20,3\%$. Dabei war auffällig, daß das CNN den Einfluss der linken Hemisphäre auf die rechte Hemisphäre bei beiden Patienten zuverlässig detektieren konnte, was durch die Optimierung mit SEEG-Zeitreihen der Elektroden TL07 und TR05 erklärt werden konnte. Für intrahemisphärische Elektrodenkombinationen zeigte das CNN dagegen eine Tendenz zu niedrigen Zellausgaben $v = -1$, was sich einerseits in hohen Approximationsfehlern sowie in falsch geschätzten mittleren Werten der CNN-basierten Approximation $S_{a,(mean)}^{(CNN)}$ äußerte.

Mit CNN(a, Pat B, TL03-TL10) konnte ein durchschnittlicher Approximationsfehler von $F_M^{(val)} = 17,7\%$ für die SEEG-Zeitreihen aller Elektrodenkombinationen von Patient B erreicht werden (siehe auch Abbildung 6.26). Wiederum wurde vor allem der Einfluss der linken Hemisphäre auf die rechte Hemisphäre mit hohen Approximationsgüten geschätzt. Dies äußerte sich auch in recht zuverlässigen Schätzungen $S_{a,(mean)}^{(CNN)}$ des über die Dauer des analysierten Datensatzes gemittelten Niveaus des asymmetrischen Interdependenzmaßes. Für die übrigen Elektrodenkombinationen zeigte die CNN-basierte Approximation teilweise sehr hohe Approximationsfehler, was darauf zurückzuführen war, daß CNN(a, Pat B, TL03-TL10) die kurzfristigen Fluktuationen der Interaktionsrichtung nicht reproduzieren konnte. Dennoch zeigte sich in der über den analysierten Datensatz gemittelten CNN-basierten Approximation $S_{a,(mean)}^{(CNN)}$ eine recht gute Schätzung der Interaktionsrichtung, die gut mit dem analytisch berechneten Interdependenzmaß $S_{a,(mean)}$ übereinstimmte. Die Ergebnis-

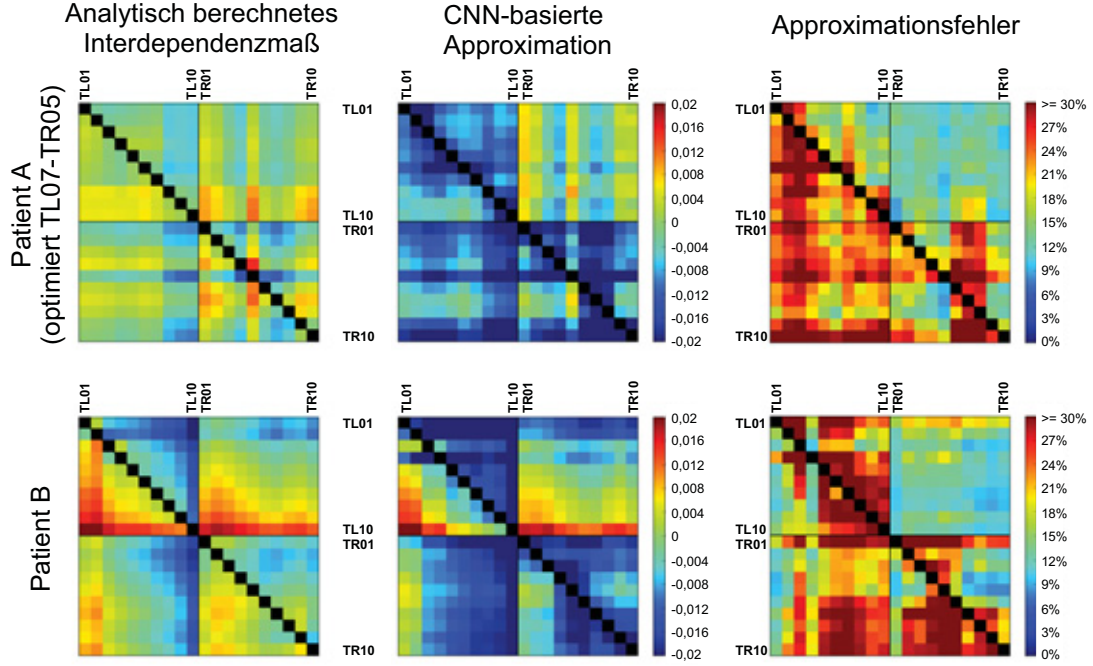


Abbildung 6.25: Über den analysierten Datensatz gemittelt analytisch berechnetes Interdependenzmaß $S_{a,(mean)}$ (links) und Approximation $S_{a,(mean)}^{(CNN)}$ (Mitte) mit CNN(a, Pat A, TL07-TR05) für die Zeitreihen aller Elektrodenkombinationen von Patient A und B. Rechts Approximationsfehler $F^{(val)}$.

se für Patient A, dessen SEEG-Zeitreihen nicht für die Optimierung von CNN(a, Pat B, TL03-TL10) genutzt wurden, waren mit einem durchschnittlichen Approximationsfehler von $F_M^{(val)} = 24,6\%$ vergleichsweise schlecht (siehe auch Abbildung 6.26 oben). Auch hier fiel wiederum auf, daß der Einfluss der Hirnstrukturen der kontralateralen linken Hemisphäre auf den epileptischen Fokus innerhalb der rechten Hemisphäre am besten geschätzt werden konnte. Für die Zeitreihen der übrigen Elektrodenkombinationen zeigte das CNN wiederum eine generelle Tendenz zu Zell-Ausgaben von $v = -1$, was zu hohen Approximationsfehlern $F^{(val)}$ und zu, über den Datensatz gemittelt, zu niedrig geschätzten CNN-basierten Approximationen $S_{a,(mean)}^{(CNN)}$ führte.

Insgesamt beschränkten sich die Generalisierungseigenschaften der CNN, die mit Zeitreihen einzelner Elektrodenkombinationen einzelner Patienten trainiert wurden, nur auf bestimmte Hirnstrukturen. Hierbei konnte jeweils der Einfluss der

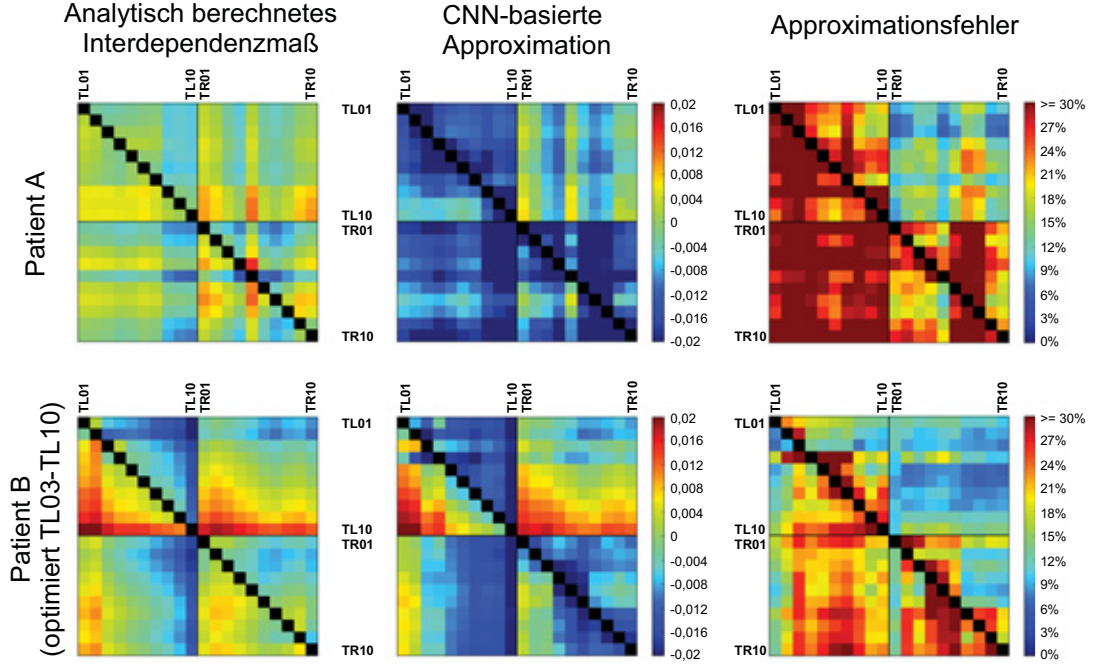


Abbildung 6.26: Über den analysierten Datensatz gemittelt analytisch berechnetes Interdependenzmaß $S_{a,(mean)}$ (links) und Approximation $S_{a,(mean)}^{(CNN)}$ (Mitte) mit CNN(a, Pat B, TL03-TL10) für die Zeitreihen aller Elektrodenkombinationen von Patient A und B. Rechts Approximationsfehler $F^{(val)}$.

kontralateralen Hemisphäre auf die fokale Hemisphäre am besten geschätzt werden. Dies könnte damit zusammenhängen, daß durch die pathologisch veränderte Dynamik innerhalb des epileptischen Fokus der Einfluss der anderen Hirnstrukturen auf diesen am deutlichsten ausgeprägt war und somit am besten mit den CNN erfasst werden konnte. Die Tatsache, daß die CNN-Ausgaben beispielsweise für intrahemisphärische Elektrodenkombinationen eine von der tatsächlichen Dynamik unabhängige Tendenz zu Zellausgaben $v = -1$ zeigten, ließ darauf schließen, daß die CNN keine Generalisierungseigenschaften für die Zeitreihen dieser Hirnstrukturen besaßen. Mit Optimierungen auf Basis von Zeitreihen einzelner Hirnstrukturen war es mit CNN also nur teilweise möglich, eine von der Dynamik unabhängige Schätzung der Interaktionsrichtung zu erhalten.

Nach diesen Ergebnissen wurde untersucht, ob durch Optimierungen mit Zeitreihen, die in verschiedenen Hirnstrukturen eines Patienten oder verschiedener Patienten aufgezeichnet wurden, eine Verbesserung der Generalisierungseigenschaften

der CNN erreicht werden konnte. Dazu wurden für die Patienten A und B jeweils Optimierungen mit SEEG-Zeitreihen von verschiedenen Elektrodenkombinationen (CNN(a, Pat A, M) und CNN(a, Pat B, M)) sowie eine Optimierung mit SEEG-Zeitreihen von verschiedenen Elektrodenkombinationen beider Patienten (CNN(a, M, M)) durchgeführt.

Wie in Abschnitt 6.7.2 erfolgte die Auswahl der Elektrodenkombinationen, an denen die Zeitreihen aufgezeichnet wurden, welche zur Optimierung benutzt wurden, zufällig. Allerdings wurden jeweils wiederum sowohl räumlich benachbarte sowie entfernt gelegene Kombinationen von Elektroden verwendet. Außerdem wurden auch wieder jeweils interhemisphärische sowie intrahemisphärische Elektrodenkombinationen (beider Hemisphären) sowie Kombinationen mit Elektroden, die die Aktivität des epileptischen Fokus aufzeichneten, gewählt. Die Ergebnisse der Validierungen dieser CNN für SEEG-Zeitreihen der Patienten A und B sind in Tabelle 6.9 zusammengefasst.

CNN	Validierung		Approximationsfehler $F_M^{(val)}$
	Patient	Elektrodenkomb.	
CNN(a, Pat A, M)	A	alle	16,3%
CNN(a, Pat A, M)	B	alle	17,9%
CNN(a, Pat B, M)	A	alle	27,6%
CNN(a, Pat B, M)	B	alle	20,8%
CNN(a, M, M)	A	alle	20,6%
CNN(a, M, M)	B	alle	17,8%

Tabelle 6.9: CNN, die in den Optimierungen mit Zeitreihen verschiedener Elektrodenkombinationen bestimmt werden konnten. Über alle Elektrodenkombinationen gemittelter Approximationsfehler (rechts) für die Zeitreihen des jeweiligen Patienten (Mitte).

Mit CNN(a, Pat A, M) konnte ein CNN bestimmt werden, welches für die SEEG-Zeitreihen von Patient A einen durchschnittlichen Approximationsfehler von $F_M^{(val)} = 16,3\%$ über alle Elektrodenkombinationen aufwies. In Abbildung 6.27 ist zu erkennen, daß insbesondere für intrahemisphärische Elektrodenkombinationen eine hohe Approximationsgüte erreicht werden konnte. Interessanterweise konnte das CNN den Einfluss der Hirnstrukturen der kontralateralen linken Hemisphäre auf die Hirnstrukturen der fokalen rechten Hemisphäre nur sehr schlecht schätzen, also genau umgekehrt wie bei den zuvor in Abschnitt 6.8.1 ermittelten CNN. Durch die Optimierung mit SEEG-Zeitreihen, die in verschiedenen Hirnstrukturen aufgezeichnet wurden, konnten in diesem Falle somit die Generalisierungseigenschaften

des CNN verbessert werden, auch wenn sie nicht uneingeschränkt für alle Hirnstrukturen galten. So konnte CNN(a, Pat A, M) auch das mittlere analytisch berechnete Interdependenzmaß $S_{a,(mean)}$ über den analysierten Datensatz recht gut schätzen. Es ist zu erkennen, daß mit diesem CNN zwar meist eine Überschätzung der Interaktion auftrat (aufgrund einer Tendenz zu hohen bzw. niedrigen Zellausgaben), aber die Richtung grundsätzlich korrekt angezeigt wurde.

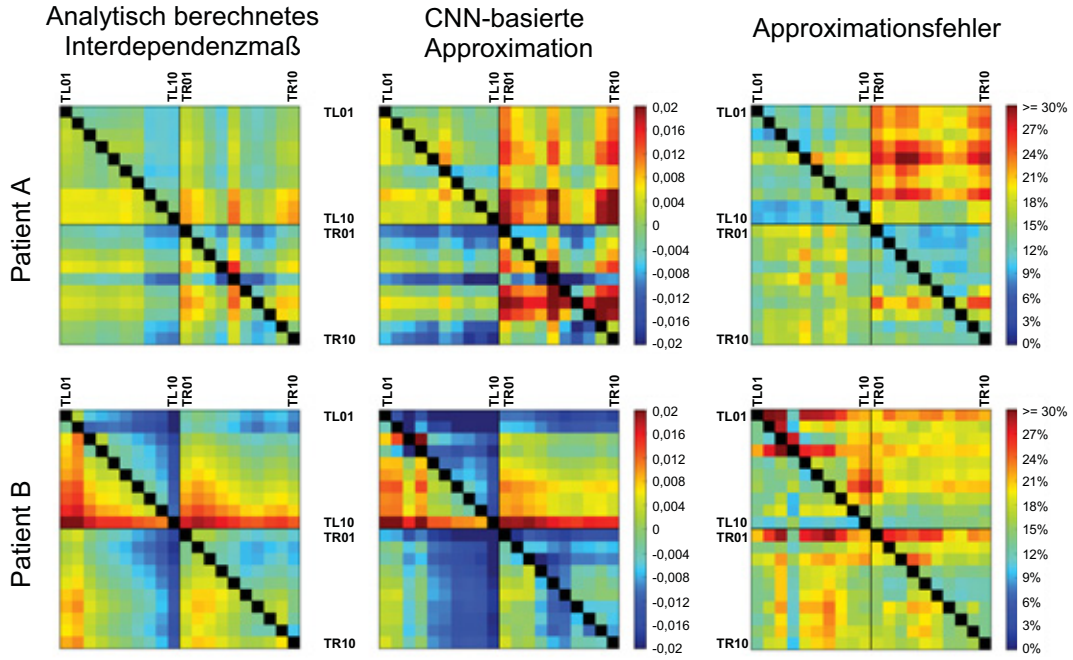


Abbildung 6.27: Über den analysierten Datensatz gemittelt analytisch berechnetes Interdependenzmaß $S_{a,(mean)}$ (links) und Approximation $S_{a,(mean)}^{(CNN)}$ (Mitte) mit CNN(a, Pat A, M) für die Zeitreihen aller Elektrodenkombinationen von Patient A und B. Rechts Approximationsfehler $F^{(val)}$.

In Abbildung 6.28 sind das analytisch berechnete Interdependenzmaß sowie die CNN-basierte Approximation beispielhaft für die SEEG-Zeitserien zweier Elektrodenkombinationen gezeigt. Der Approximationsfehler für die Elektrodenkombination TL03-TL01 (oben) betrug $F_{(TL03-TL01)}^{(val)} = 9,8\%$. Das CNN bot dabei eine sehr gute Approximation der kurz- und langfristigen Fluktuationen der Interaktionsrichtung. Für die Zeitserien der Elektrodenkombination TL05-TR03 (unten) wies das CNN dagegen einen Approximationsfehler von $F_{(TL05-TR03)}^{(val)} = 31\%$ auf. Hier ist zu erkennen, daß das CNN eine generelle Tendenz zu hohen Zellausgaben $v = 1$ besaß und somit teilweise fälschlich einen starken Einfluss der Hirnstruktur um Elektrode

TL05 auf die Hirnstruktur um Elektrode TR03 anzeigte.




Abbildung 6.28: Zeitlicher Verlauf des analytisch berechneten Interdependenzmaßes sowie der Approximation mit CNN(a, Pat A, M) für eine etwa 18 Stunden dauernde SEEG-Aufzeichnung, oben Elektrodenkombination TL03-TL01 von Patient A ($F_{(TL03-TL01)}^{(val)} = 9,8\%$), unten Elektrodenkombination TL05-TR03 von Patient A ($F_{(TL05-TR03)}^{(val)} = 31\%$); rote Markierungen entsprechen elektrischem Anfallsbeginn.

Für die SEEG-Zeitreihen von Patient B erreichte CNN(a, Pat A, M) einen Approximationsfehler von $F_M^{(val)} = 17,9\%$ gemittelt über alle Elektrodenkombinationen (siehe auch Abbildung 6.27). Es ist zu erkennen, daß das über den analysierten Datensatz gemittelte analytisch berechnete Interdependenzmaß $S_{a,(mean)}$ sehr gut mit dem CNN geschätzt werden konnte, auch wenn teilweise wieder eine Tendenz zu niedrigen bzw. hohen Zellausgaben und somit eine Überschätzung des Einflusses der Hirnstrukturen aufeinander vorlag.

Die Optimierung von CNN(a, Pat B, M) mit SEEG-Zeitreihen die an verschiedenen Elektrodenkombinationen von Patient B aufgezeichnet wurden, ergab für bestimmte Hirnstrukturen gute Generalisierungseigenschaften (siehe Abbildung 6.29). So konnte bei einem durchschnittlichen Approximationsfehler über alle Elektrodenkombinationen von $F_M^{(val)} = 20,8\%$ der Einfluss der Hirnstrukturen der rechten fokalen Hemisphäre auf die Hirnstrukturen der linken Hemisphäre mit einer hohen

Güte mit dem CNN reproduziert werden. Trotz der teilweise sehr hohen Approximationsfehler $F^{(val)}$ aufgrund der mit CNN(a, Pat B, M) schlecht reproduzierten kurzfristigen Fluktuationen des analytisch berechneten Interdependenzmaßes zeigte das CNN dennoch eine gute Schätzung des über den analysierten Datensatz gemittelten analytisch berechneten Interdependenzmaßes $S_{a,(mean)}$. Allerdings wurde hier aufgrund der Tendenz zu Zellausgaben $v = 1$ von CNN(a, Pat B, M) der Grad der asymmetrischen Kopplung meist überschätzt.

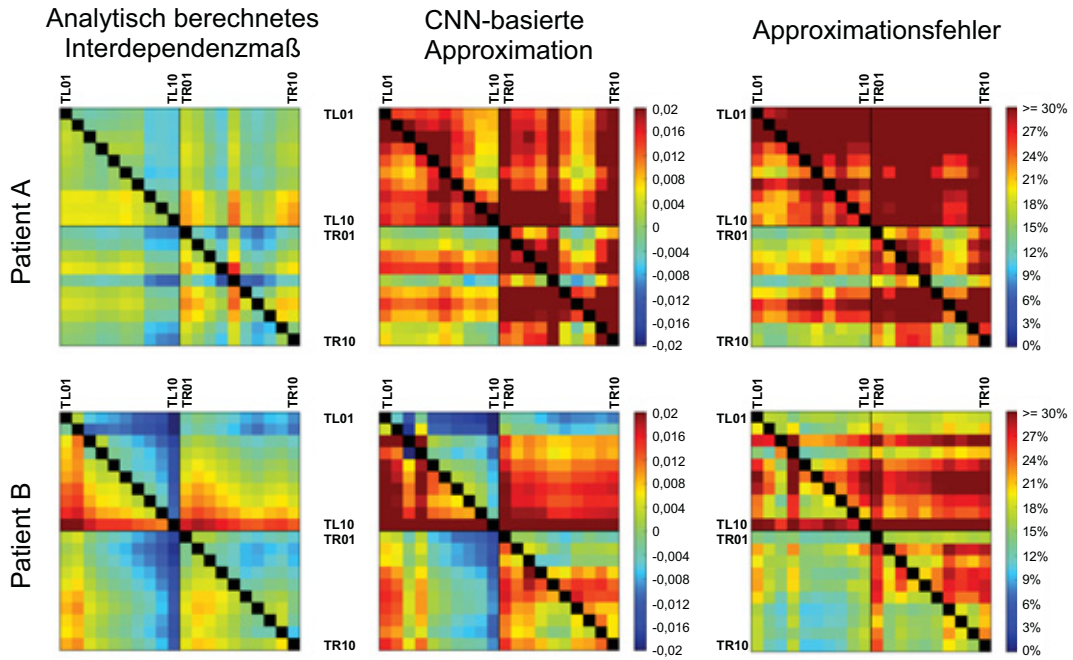


Abbildung 6.29: Über den analysierten Datensatz gemitteltes analytisch berechnetes Interdependenzmaß $S_{a,(mean)}$ (links) und Approximation $S_{a,(mean)}^{(CNN)}$ (Mitte) mit CNN(a, Pat B, M) für die Zeitreihen aller Elektrodenkombinationen von Patient A und B. Rechts Approximationsfehler $F^{(val)}$.

In Abbildung 6.30 sind beispielhaft für die Zeitreihen zweier Elektrodenkombinationen das analytisch berechnete Interdependenzmaß sowie die CNN-basierte Approximation gezeigt. Für die Elektrodenkombination TR07-TL05 konnte mit CNN(a, Pat B, M) eine sehr gute Schätzung der kurz- und langfristigen Fluktuationen der Interaktionsrichtung erzielt werden. Dagegen zeigte CNN(a, Pat B, M) einen Einfluss der Hirnstruktur um Elektrode TL03 auf die Hirnstruktur um Elektrode TR09 an, der vom analytisch berechneten Interdependenzmaß jedoch in umgekehr-




Abbildung 6.30: Zeitlicher Verlauf des analytisch berechneten Interdependenzmaßes sowie der Approximation mit CNN(a, Pat B, M) für eine etwa 18 Stunden dauernde SEEG-Aufzeichnung, oben Elektrodenkombination TR07-TL05 von Patient B ($F_{(TR07-TL05)}^{(val)} = 10,2\%$), unten Elektrodenkombination TL03-TR09 von Patient B ($F_{(TL03-TR09)}^{(val)} = 30\%$); rote Markierungen entsprechen elektrischem Anfallsbeginn.

ter Richtung detektiert wurde.

Die Generalisierungseigenschaften von CNN(a, Pat B, M) für die SEEG-Zeitreihen von Patient A waren mit einem mittleren Approximationsfehler von $F_M^{(val)} = 27,6\%$ für alle Elektrodenkombinationen vergleichsweise schlecht (siehe auch Abbildung 6.29). Es ist zu erkennen, daß sehr hohe Approximationsfehler auftraten, da das CNN nicht in der Lage war, kurzfristige Fluktuationen der Interaktionsrichtung zu detektieren. Darüber hinaus zeigte CNN(a, Pat B, M) auch eine generelle Tendenz zu Zellausgaben $v = 1$, wodurch für viele Elektrodenkombinationen auch die aus $S_{a,(mean)}$ folgende Interaktionsrichtung nicht korrekt detektiert werden konnte.

CNN(a, M, M), welches mit SEEG-Zeitreihen optimiert wurde, die an verschiedenen Elektrodenkombinationen der beiden Patienten A und B aufgezeichnet wurden, wies Approximationsfehler von $F_M^{(val)} = 20,6\%$ für die SEEG-Zeitreihen von Patient A und $F_M^{(val)} = 17,8\%$ für die SEEG-Zeitreihen von Patient B auf (siehe auch Abbildung 6.31). Es ist zu erkennen, daß wie bei CNN(a, Pat A, M) und CNN(a, Pat B,

M) wiederum vor allem der Einfluss der Hirnstrukturen der linken Hemisphäre auf die Hirnstrukturen der rechten Hemisphäre nur mit hohen Approximationsfehlern geschätzt werden konnte. Ebenfalls wurden für die entsprechenden Elektrodenkombinationen bei Patient A viele Fehldetektionen auch in den über den analysierten Datensatz gemittelten Interaktionsrichtungen festgestellt. Für Patient B zeigte sich hier jedoch eine recht zuverlässige Schätzung des über den analysierten Datensatz gemittelten analytisch berechneten Interdependenzmaßes $S_{a,(mean)}$.

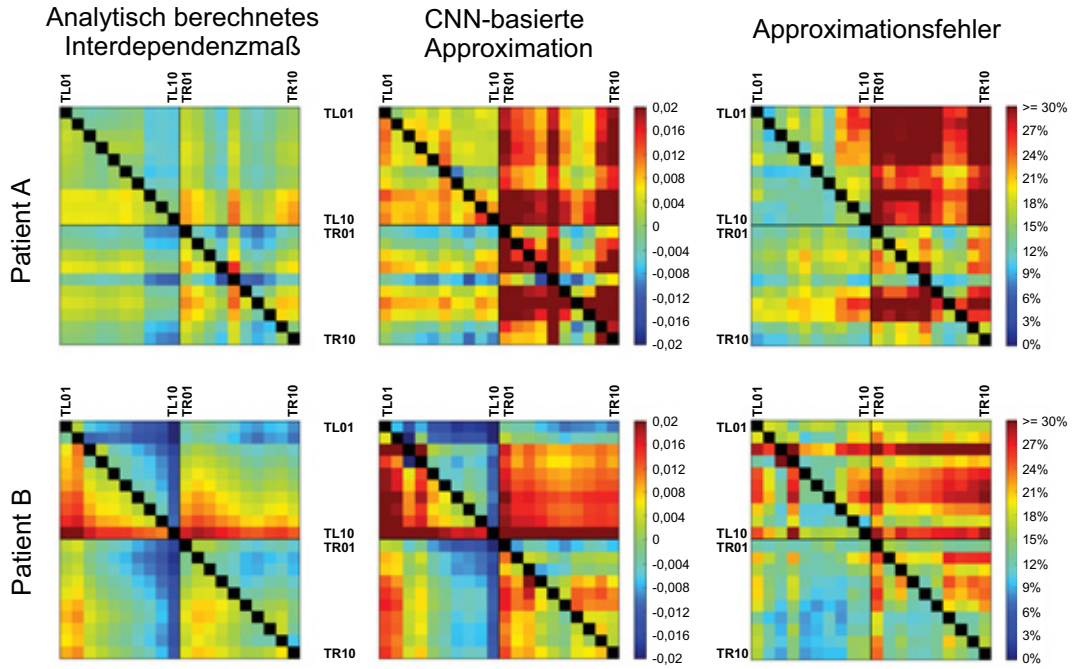


Abbildung 6.31: Über den analysierten Datensatz gemitteltes analytisch berechnetes Interdependenzmaß $S_{a,(mean)}$ (links) und Approximation $S_{a,(mean)}^{(CNN)}$ (Mitte) mit CNN(a, M, M) für die Zeitreihen aller Elektrodenkombinationen von Patient A und B. Rechts Approximationsfehler $F^{(val)}$.

Durch Optimierungen anhand von SEEG-Zeitreihen einzelner interhemisphärischer und intrahemisphärischer Elektrodenkombinationen konnten CNN bestimmt werden, welche die Interaktionsrichtung zwischen den entsprechenden Hirnstrukturen schätzen konnten. Lediglich für Elektrodenkombinationen innerhalb des epileptischen Fokus war dies nicht möglich, was auf die erhöhte Interaktionsstärke innerhalb dieser Hirnstruktur zurückgeführt werden konnte. Die Untersuchung der Generalisierungseigenschaften ergab, daß kein universelles CNN gefunden werden

konnte, welches eine zuverlässige Schätzung der Interaktionsrichtung zwischen allen hier untersuchten Hirnstrukturen bot. Dennoch konnten verschiedene CNN zumindest für einige Hirnstrukturen eine gute Schätzung der Interaktionsrichtung bieten. Im nächsten Abschnitt soll daher überprüft werden, ob - ähnlich wie in Abschnitt 6.7.3 für die Interaktionsstärke - zeitliche Variationen der von CNN geschätzten Interaktionsrichtung zum Nachweis eines Voranfallszustandes ausgenutzt werden können.

6.8.3 Prädiktive Merkmale

Für die Untersuchung eines angenommenen Voranfallszustandes mit einem Maß zur Detektion einer Interaktionsrichtung treten die gleichen offenen Fragestellungen auf wie bei den Maßen zur Charakterisierung der Interaktionsstärke (siehe auch Abschnitt 6.7.3). Auch hier muß beispielsweise geklärt werden, wie ein Voranfallszustand statistisch signifikant nachgewiesen werden kann. Darüber hinaus müssten für eine Anfallsvorhersage auch hier zunächst geeignete prospektive Algorithmen entwickelt werden. Im folgenden wurden daher wieder retrospektiv die Verteilungen der Werte des analytisch berechneten Interdependenzmaßes S_a bzw. der CNN-basierten Approximation $S_a^{(\text{CNN})}$ für Zeitreihen aus dem präiktalen und interiktalen Intervall (wie in Abschnitt 6.7.3 wurde wiederum eine Dauer von 240 Minuten für einen hypothetischen Voranfallszustand angenommen) untersucht. Dabei wurden die gleichen SEEG-Aufzeichnungen analysiert, wie in Abschnitt 6.8.2 (Patient A 18 Stunden, Patient B 16 Stunden, jeweils 1 Anfall innerhalb der Aufzeichnung).

Exemplarisch sind in Abbildung 6.32 die relativen Häufigkeiten des analytisch berechneten Interdependenzmaßes sowie der Approximation mit CNN(a, Pat A, M) im interiktalen und präiktalen Intervall für die Zeitreihen der Elektrodenkombination TL06-TL02 von Patient A gezeigt. Es ist zu erkennen, daß durch den Approximationsfehler von $F_{(\text{TL06-TL02})}^{(\text{val})} = 12,5\%$ zwar eine Verbreiterung der Verteilungen auftritt, jedoch die Tendenz zu niedrigeren Werten für Zeitreihen aus dem präiktalen gegenüber dem interiktalen Intervall erhalten bleibt.

In Abbildung 6.33 sind die relativen Häufigkeiten des analytisch berechneten Interdependenzmaßes S_a bzw. der Approximation $S_a^{(\text{CNN})}$ mit CNN(a, Pat A, M) im interiktalen und präiktalen Intervall für die Zeitreihen der Elektrodenkombination TR03-TR05 von Patient B gezeigt. Es ist zu erkennen, daß CNN(a, Pat A, M) für die Daten von Patient B, dessen SEEG-Zeitreihen nicht zur Optimierung genutzt wurden, eine Tendenz zu Zellausgaben $v = -1$ zeigte, wodurch eine Verschiebung der Verteilungen zu niedrigen Werten auftrat (Approximationsfehler von $F_{(\text{TR03-TR05})}^{(\text{val})} = 22,9\%$). Dennoch wurde die Tendenz zu niedrigeren Werten für

Zeitreihen aus dem präiktalen Intervall verglichen mit dem interiktalen von CNN(a, Pat A, M) reproduziert.




Abbildung 6.32: Relative Häufigkeiten des analytisch berechneten Interdependenzmaßes (links) und der CNN-basierten Approximation (rechts) für Zeitreihen der Elektrodenkombination TL06-TL02 aus dem interiktalen und präiktalen Intervall von Patient A; Histogramm mit Klassengröße 0,002.




Abbildung 6.33: Wie Abbildung 6.32 nur für Zeitreihen der Elektrodenkombination TR03-TR05 von Patient B.

6.8.4 Diskussion

Die durchgeführten Untersuchungen zeigten, daß es möglich ist, mit CNN die Interaktionsrichtung zwischen verschiedenen Hirnstrukturen zu schätzen. Es konnten hierbei CNN gefunden werden, die sowohl kurz- als auch langfristige Fluktuationen eines für SEEG-Zeitreihen berechneten asymmetrischen Interdependenzmaßes sehr gut reproduzierten. Dies galt für intrahemisphärische sowie für interhemisphärische Elektrodenkombinationen und ebenfalls für Elektroden, welche die Zeitreihen hirnelektrischer Aktivität des epileptischen Fokus aufzeichneten. Die Generalisierungseigenschaften dieser CNN, welche anhand von Zeitreihen einzelner Elektrodenkombinationen optimiert wurden, waren dagegen eher schlecht. Einerseits wurden sehr große Approximationsfehler festgestellt, was eine Folge der schlecht reproduzierten kurzzeitigen Fluktuationen der Interaktionsrichtung war, sowie ebenfalls Fehldetektionen der über die jeweils analysierten Datensätze gemittelten Interaktionsrichtung. Durch Optimierungen mit Zeitreihen von verschiedenen Hirnstrukturen konnte für beide Patienten jeweils ein CNN gefunden werden, welches die über die analysierten Datensätze gemittelte Interaktionsrichtung korrekt detektieren konnte. Die kurzfristigen Fluktuationen der Interaktionsrichtung wurden darüber hinaus für viele Hirnstrukturen mit hoher Güte approximiert. Die Generalisierungseigenschaften für die Zeitreihen des jeweils anderen Patienten beschränkten sich auf bestimmte Hirnstrukturen. Ähnlich verhielt es sich mit dem CNN, welches durch die Optimierung mit Zeitreihen verschiedener Hirnstrukturen verschiedener Patienten gefunden wurde. Für einen Teil der Hirnstrukturen konnte die Interaktionsrichtung korrekt detektiert werden, während die Approximation für andere Hirnstrukturen hohe Fehler aufwies. Hierbei zeigten die CNN sehr häufig generelle Tendenzen zu Zellausgaben von $v = \pm 1$, die nicht mit der Interaktionsrichtung zwischen den Hirnstrukturen zusammenhingen. Somit war es im Gegensatz zur Messung der Interaktionsstärke im vorigen Abschnitt 6.7 nicht möglich, ein universelles CNN zu bestimmen, welches eine Interaktionsrichtung zwischen allen hier untersuchten Hirnstrukturen verschiedener Patienten zuverlässig schätzen konnte. Auffälligerweise wiesen häufig Kombinationen mit Elektroden, welche im epileptischen Fokus lagen, eine besonders schlechte Approximationsgüte auf. Dies könnte auf eine erhöhte Interaktionsstärke zurückzuführen sein, die eine Detektion einer Interaktionsrichtung erschwert. Es wäre folglich für eine Anwendung, bei der die Zeitreihen einer großen Anzahl von Elektroden verarbeitet werden sollen, notwendig, spezifische Optimierungen für jede Elektrodenkombination durchzuführen. In diesem Zusammenhang kommt hinzu, daß keine Gemeinsamkeiten bei den Templates der hier gefundenen CNN auftraten (siehe Anhang B), so daß auch hier keine Hinweise auf ein universelles CNN vorlagen. Dennoch konnte nachgewiesen werden, daß für die Zeitreihen von Hirnstrukturen, für die der Approximationsfehler klein genug war, die zeitlichen Variationen der Interaktionsrichtung bezüglich eines

hypothetischen Voranfallszustandes von CNN reproduziert wurden.

7 Zusammenfassung und Ausblick

In dieser Arbeit wurden Stärke und Richtung von Interaktionen zwischen dynamischen Systemen mit Zellularen Neuronalen Netzen (CNN) charakterisiert. Als Grundlage dafür wurden nichtlineare Interdependenzmaße genutzt, die einen Schätzer für generalisierte Synchronisation darstellen und auf geometrischen Beziehungen zwischen den in Zustandsräumen rekonstruierten Systemdynamiken basieren, weshalb sowohl Phasen- als auch Amplitudeninformationen relevant sind. Darüber hinaus bieten nichtlineare Interdependenzmaße die Möglichkeit, sowohl die Stärke als auch die Richtung von Interaktionen zu schätzen. Trotz der konzeptionellen Einfachheit dieser Maße sind Algorithmen zu deren Berechnung mit einem hohen Rechenaufwand verbunden. Hinzu kommt, daß dieser, da es sich um bivariate Kenngrößen handelt, quadratisch mit der Anzahl der untersuchten Systeme ansteigt. Beide Aspekte schränken Analysen von Felddaten mit Computern der von Neumann-Architektur stark ein. Es wurde daher untersucht, inwiefern die attraktiven Eigenschaften der Informationsverarbeitung künstlicher neuronaler Netze für eine Approximation nichtlinearer Interdependenzmaße und damit zur Charakterisierung von Interaktionen zwischen dynamischen Systemen ausgenutzt werden können. Hierbei wurde auf Zellulare Neuronale Netze zurückgegriffen, da diese eine vergleichsweise einfache Simulation am Rechner erlauben und bereits schaltungstechnische Implementationen zur Verfügung stehen. Üblicherweise werden CNN im Forschungsgebiet der nichtlinearen Dynamik beispielsweise durch die Möglichkeit, chaotisches Verhalten zu erzeugen, als Generatoren verschiedener Dynamiken verwendet [TGC09]. Jedoch konnte in verschiedenen Arbeiten auch ihre Eignung als Werkzeug zur Analyse nichtlinearer Dynamiken nachgewiesen werden [TKAW99, Kra06, Wan07, Sow04, SCML05, CMM⁺05, CL07].

Um nichtlineare Interdependenzmaße mit CNN zu approximieren, wurde ein überwachtes Lernverfahren angewendet, bei dem durch die iterative Minimierung einer Kostenfunktion auf Basis von Beispieldaten die Zellkopplungsgewichte der CNN optimiert wurden. Zunächst wurden die Grenzen dieser Methode anhand von synthetischen Zeitreihen von Modellsystemen überprüft, deren Eigenschaften wohlbekannt sind und durch Kontrollparameter gesteuert werden können. Dabei erwiesen sich CNN als geeignet, sowohl die Stärke als auch die Richtung von Interaktionen zwischen strukturell ähnlichen Systemen zu schätzen. Hierbei konnten jeweils

die theoretisch zu erwartenden Abhängigkeiten des symmetrischen sowie asymmetrischen nichtlinearen Interdependenzmaßes von der Kopplungsstärke zwischen den Systemen mit CNN reproduziert werden. Dies ermöglichte einerseits die Unterscheidung der verschiedenen Regimes unabhängiger, intermittenter und synchronisierter Systeme sowie andererseits die korrekte Detektion der Interaktionsrichtung im Falle schwach interagierender Systeme. Da bei der Analyse von Felddaten im Allgemeinen nicht davon ausgegangen werden kann, daß Systeme mit ähnlicher Dynamik vorliegen, wurden zudem strukturell unterschiedliche Modellsysteme untersucht. Hier konnte gezeigt werden, daß CNN auch zwischen diesen eine zuverlässige Charakterisierung der Interaktionsstärke und Interaktionsrichtung bieten.

Zur Überprüfung der Eignung von CNN zur Charakterisierung von Interaktionen zwischen komplexen natürlichen dynamischen Systemen wurden lang andauernde (mehrere Tage) Vielkanalaufzeichnungen hirnelektrischer Aktivität von Patienten mit einer fokalen Epilepsie beispielhaft untersucht. Dabei war es möglich, die Interaktionsstärke und Interaktionsrichtung zwischen verschiedenen Hirnstrukturen mit unterschiedlichen Dynamiken mit hoher Güte mit CNN zu schätzen, welche anhand von Beispielzeitreihen von lediglich etwa 5 Minuten Dauer optimiert wurden. Auch konnten Änderungen der Dynamik aufgrund physiologischer Einflussfaktoren (z.B. Schlaf-Wach-Rhythmen) und pathophysiologischer Aktivität wie z.B. epileptischer Anfälle reproduziert werden. Am Beispiel von Zeitreihen hirnelektrischer Aktivität konnte demnach nachgewiesen werden, daß CNN in der Lage sind, auch für nichtstationäre dynamische Systeme eine Schätzung der Interaktionsstärke und -richtung zu bieten. Darüber hinaus wurden die Generalisierungseigenschaften von CNN untersucht. CNN konnten dabei die Interaktionsstärke nicht nur für verschiedene Hirnstrukturen sondern auch für verschiedene Patienten ohne individuelle Optimierung mit hoher Güte schätzen. Für die Charakterisierung der Interaktionsrichtung war dies ebenfalls grundsätzlich möglich. Allerdings zeigte die CNN-basierte Approximation für die Interaktionen zwischen einzelnen Hirnstrukturen teilweise hohe Fehler. In diesem Zusammenhang muß die Frage gestellt werden, inwiefern Systemeigenschaften einen Einfluss auf die Detektierbarkeit einer Interaktionsrichtung hatte. In [AGLE99, QAG00] wurden zum Beispiel Hinweise gefunden, daß auch Eigenschaften der Systeme wie beispielsweise der Grad der Komplexität (beispielsweise durch Schätzer der Korrelationsdimension bestimmbar) - unabhängig von Synchronisationsphänomenen - durchaus einen Einfluss auf die Richtungsdetektion mit nichtlinearen Interdependenzmaßen haben können. Inwiefern dies für EEG-Zeitreihen relevant ist, konnte bis heute nicht abschließend geklärt werden. An dieser Stelle sind ebenfalls die teilweise widersprüchlichen Resultate zu erwähnen, die in unterschiedlichen Studien mit verschiedenen Ansätzen zur Richtungsdetektion in EEG-Zeitreihen erhalten wurden. So wurden in [SL08b] mit einem informationstheoretischen Maß in den Daten eines 15 Patienten umfassenden Kollektivs Hinweise gefunden, daß ein Informationsfluss von der fokalen zur nicht-fokalen Hemisphäre

auftritt. In [Ost08] konnte dagegen mit einem phasenbasierten Richtungsmaß in bestimmten Frequenzbändern der umgekehrte Effekt nachgewiesen werden. Ebenso wurde mit einer datengetriebenen Schätzung von Drift und Diffusion einer Fokker-Planck- bzw. Langevin-Gleichung ein Informationsfluss von der nicht-fokalen zur fokalen Hemisphäre beobachtet [PL07]. Ähnlich widersprüchliche Ergebnisse wurden auch für andere dynamische Systeme beobachtet, so daß es nicht überraschend ist, daß die robuste Detektion von Richtungsabhängigkeiten Gegenstand aktueller Forschung ist. Es wurden in verschiedenen Studien durch den Vergleich von Richtungsmaßen auf Basis verschiedener Konzepte Informationen darüber gewonnen, unter welchen Bedingungen diese eine identische Interaktionsrichtung detektieren [RTKG07, HSPVB07, FPN08, OMWL08, NZN⁺08]. In Erweiterung der zur Detektion komplexer Synchronisation eingesetzten Surrogate [SS00, TRK⁺06] wurden Surrogattechniken vorgeschlagen, um falsch detektierte Kausalitäten zu identifizieren [PV07, Pal08, RTK⁺09]. Darüber hinaus wurden auch Methoden zur Unterscheidung direkter von indirekten Interaktionen [NRT⁺10] entwickelt. Unabhängig von den zur Zeit noch diskutierten Problemen der Messung von Interaktionsrichtungen zeigen die Ergebnisse der Untersuchungen der Generalisierungseigenschaften jedoch, daß CNN, die anhand der Dynamik bestimmter Systeme optimiert wurden, auch die Dynamik ähnlicher Systeme verarbeiten können.

Abschließend wurde die Eignung der CNN-basierten Approximationen für die Detektion von Merkmalen untersucht, die auf einen bevorstehenden epileptischen Anfall hindeuten. Die zur Zeit üblichen retrospektiven Analysen zum Nachweis eines Voranfallszustandes basieren auf der Annahme, daß vor einem Anfall - verglichen mit der übrigen anfallsfreien Zeit - eine Änderung der Interaktionsstärke bzw. der Interaktionsrichtung auftritt. Viele aktuelle Studien befassten sich mit der Frage, wie solche Effekte statistisch validiert werden können, beispielsweise durch Surrogattechniken [AMK⁺03, AKS⁺03, KAM⁺04, MKR⁺05, SWM⁺06, ACEM09]. In der vorliegenden Arbeit konnte gezeigt werden, daß die Variationen der nichtlinearen Interdependenzmaße für Stärke und Richtung bezüglich eines Voranfallszustandes mit CNN reproduziert werden können. Dies galt allerdings unter der Einschränkung kleiner Approximationsfehler der CNN-basierten Approximation (im Bereich von 10% oder besser), da es sich um sehr subtile Variationen der analytisch berechneten Interdependenzmaße handelte. Auch im Hinblick auf andere Anwendungsgebiete, die möglicherweise noch feinere Variationen erfassen, wäre daher eine Verbesserung der Approximationsgüte wünschenswert. Dies wäre eventuell durch eine Erhöhung des polynomiellen Grades der Templates zu erreichen, wobei hier sichergestellt werden müsste, daß das Optimierungsverfahren trotz der erhöhten Dimensionalität des Feherraums lokale Minima findet. Hier könnte alternativ zu approximativen Verfahren, bei denen Maße von CNN erlernt werden, auf bereits vorhandene Templatebibliotheken zurückgegriffen werden. So ist es bereits möglich, informationstheoretische Maße mit jeweils einem Satz von bekannten Templates exakt mit CNN zu

berechnen [Wan07, Glü09]. Einen weiteren Ansatzpunkt könnte die Anordnung der Daten in den CNN darstellen. Durch die bisher verwendete zeilenweise Anordnung der Zeitreihen in den CNN werden - abhängig von der Netzgröße - Korrelationen hergestellt. So wurden in [Dic10] Hinweise gefunden, daß durch die Einführung komplexer Zellkopplungstopologien effektivere CNN-Optimierungen möglich sein könnten. In diesem Zusammenhang wären auch dreidimensionale CNN denkbar, bei denen bei der Anordnung der Zeitreihen sowohl die zeitlichen als auch räumlichen Korrelationen von Zustandsvektoren, die zur Berechnung von Interdependenzmaßen benötigt werden, erhalten bleiben.

Durch die Fähigkeit von CNN, Interaktionsstärke und -richtung sogar zwischen nichtstationären dynamischen Systemen zu charakterisieren sowie durch die ebenfalls vorhandenen Generalisierungseigenschaften könnten CNN in vielen Anwendungsbereichen eingesetzt werden. Besonders interessant sind in diesem Zusammenhang die bereits verfügbaren analogen schaltungstechnischen Realisationen von CNN [RRV00, RR02, RLC⁺04], die sich durch eine hohe Verarbeitungsgeschwindigkeit bei niedrigem Energie- und Raumbedarf auszeichnen. Es wurden zudem bereits CNN mit polynomiellen Zellkopplungen bis zur 3. Ordnung realisiert [LPKH02, LPKH04], so daß die in dieser Dissertation verwendeten Templates direkt eingesetzt werden könnten. Allerdings bleibt in zukünftigen Studien zu untersuchen, inwiefern hardwarespezifische Aspekte wie fertigungstechnische Toleranzen, thermisches Rauschen, geringere Auflösung etc. eine Nachoptimierung der hier in Softwaresimulationen entwickelten CNN erforderlich machen. Hier könnten sich eventuell digitale schaltungstechnische Realisationen auf Basis von FPGA als vorteilhaft erweisen [VKNS08]. Diese sind flexibler als Anwendungsspezifische Integrierte Schaltungen (ASIC), so daß CNN mit verschiedenen Templates auf einem Chip realisiert werden könnten, weisen jedoch einen höheren Energiebedarf auf.

Mit einer vom Einsatzzweck abhängig gewählten schaltungstechnischen Realisation von CNN könnten auf Basis der Ergebnisse dieser Arbeit miniaturisierte Systeme entwickelt werden, die Stärke und Richtung von Interaktionen zwischen dynamischen Systemen charakterisieren. Durch die hohe Verarbeitungsgeschwindigkeit und den geringen Energieverbrauch von CNN sind dabei viele Einsatzmöglichkeiten auch außerhalb der Physik in Bereichen wie Medizin, Biologie, Chemie etc. denkbar.

A Modellsysteme

A.1 Rössleroszillator

Der Rössleroszillator [Rös76] ist ein dynamisches System mit - bei geeigneter Wahl von Parametern - chaotischer Dynamik, dessen zeitliche Entwicklung durch drei Differentialgleichungen beschrieben wird:

$$\begin{aligned}\dot{\kappa}_{r1} &= -\omega\kappa_{r2} - \kappa_{r3} \\ \dot{\kappa}_{r2} &= \omega\kappa_{r1} + 0,165\kappa_{r2} \\ \dot{\kappa}_{r3} &= 0,2 + \kappa_{r3}(\kappa_{r1} - 10)\end{aligned}\tag{A.1}$$




Abbildung A.1: Zustandsraum des Rösslerattraktors, der durch die drei Komponenten aufgespannt wird.

Die Startwerte wurden für jede Realisation zufällig aus folgenden Intervallen

gewählt:

$$\begin{aligned}\kappa_{r1}(0) &\in [0, 5; 1, 5] \\ \kappa_{r2}(0) &\in [0, 5; 1, 5] \\ \kappa_{r3}(0) &\in [0, 5; 1, 5]\end{aligned}\tag{A.2}$$

A.2 Lorenzoszillator

Der Lorenzoszillator [Lor63] ist ein dynamisches System mit - bei geeigneter Wahl von Parametern - chaotischer Dynamik, dessen zeitliche Entwicklung durch drei Differentialgleichungen beschrieben wird:

$$\begin{aligned}\dot{\kappa}_{l1} &= -\frac{8}{3}\kappa_{l1} + \kappa_{l2}\kappa_{l3} \\ \dot{\kappa}_{l2} &= 28\kappa_{l3} - \kappa_{l2} - \kappa_{l1}\kappa_{l3} \\ \dot{\kappa}_{l3} &= 10(\kappa_{l2} - \kappa_{l3})\end{aligned}\tag{A.3}$$




Abbildung A.2: Zustandsraum des Lorenzattraktors, der durch die drei Komponenten aufgespannt wird.

Die Startwerte wurden für jede Realisation jeweils zufällig aus folgenden Intervallen gewählt [Ost08]:

$$\begin{aligned}\kappa_{l1}(0) &\in [41,08; 41,09] \\ \kappa_{l2}(0) &\in [7,414; 7,424] \\ \kappa_{l3}(0) &\in [14,53; 14,54]\end{aligned}\tag{A.4}$$

A.3 Bidirektional gekoppelte Rössleroszillatoren

Für die Realisierung einer bidirektionalen Kopplung wurden zwei Rössleroszillatoren X und Y gemäß Gleichung A.1 herangezogen, welche wechselseitig durch einen diffusiven Kopplungsterm (siehe Abschnitt 2.2) in der ersten Komponente des anderen Systems eingekoppelt wurden:

$$\begin{aligned}\dot{\kappa}_{r1} &= -\omega_X \kappa_{r2} - \kappa_{r3} + \epsilon_{YX}(\lambda_{r1} - \kappa_{r1}) \\ \dot{\kappa}_{r2} &= \omega_X \kappa_{r1} + 0,165 \kappa_{r2} \\ \dot{\kappa}_{r3} &= 0,2 + \kappa_{r3}(\kappa_{r1} - 10) \\ \dot{\lambda}_{r1} &= -\omega_Y \lambda_{r2} - \lambda_{r3} + \epsilon_{XY}(\kappa_{r1} - \lambda_{r1}) \\ \dot{\lambda}_{r2} &= \omega_Y \lambda_{r1} + 0,165 \lambda_{r2} \\ \dot{\lambda}_{r3} &= 0,2 + \lambda_{r3}(\lambda_{r1} - 10)\end{aligned}\tag{A.5}$$

Die Startbedingungen wurden jeweils gemäß A.2 gewählt.

A.4 Unidirektional gekoppelte Rössleroszillatoren

Für die Realisierung einer unidirektionalen Kopplung wurden zwei Rössleroszillatoren X und Y gemäß Gleichung A.1 herangezogen und X durch einen diffusiven Kopplungsterm (siehe 2.2) in die erste Komponente von Y eingekoppelt:

$$\begin{aligned}
 \dot{\kappa}_{r1} &= -\omega_X \kappa_{r2} - \kappa_{r3} \\
 \dot{\kappa}_{r2} &= \omega_X \kappa_{r1} + 0,165 \kappa_{r2} \\
 \dot{\kappa}_{r3} &= 0,2 + \kappa_{r3}(\kappa_{r1} - 10) \\
 \dot{\lambda}_{r1} &= -\omega_Y \lambda_{r2} - \lambda_{r3} + \epsilon_{XY}(\kappa_{r1} - \lambda_{r1}) \\
 \dot{\lambda}_{r2} &= \omega_Y \lambda_{r1} + 0,165 \lambda_{r2} \\
 \dot{\lambda}_{r3} &= 0,2 + \lambda_{r3}(\lambda_{r1} - 10)
 \end{aligned} \tag{A.6}$$

Die Startbedingungen wurden jeweils gemäß A.2 gewählt.

A.5 Unidirektional gekoppelte Rössler- und Lorenzoszillatoren

Der Rössleroszillator fungierte als treibendes System, indem die erste Komponente in die erste Komponente des Lorenzsystems diffusiv eingekoppelt wurde:

$$\begin{aligned}
 \dot{\kappa}_{r1} &= -0,89 \kappa_{r2} - \kappa_{r3} \\
 \dot{\kappa}_{r2} &= 0,89 \kappa_{r1} + 0,165 \kappa_{r2} \\
 \dot{\kappa}_{r3} &= 0,2 + \kappa_{r3}(\kappa_{r1} - 10) \\
 \dot{\lambda}_{l1} &= -\frac{8}{3} \lambda_{l1} + \lambda_{l2} \lambda_{l3} + \epsilon(\kappa_{r1} - \lambda_{l1}) \\
 \dot{\lambda}_{l2} &= 28 \lambda_{l3} - \lambda_{l2} - \lambda_{l1} \lambda_{l3} \\
 \dot{\lambda}_{l3} &= 10(\lambda_{l2} - \lambda_{l3})
 \end{aligned} \tag{A.7}$$

Die Startbedingungen wurden für den Rössleroszillator gemäß A.2 und für den Lorenzoszilator gemäß A.4 gewählt.

B Verzeichnis der CNN-Templates

Im folgenden sind sämtliche in der Arbeit verwendeten Templates aufgelistet. Die Angabe der Nachkommastellen ist notwendig, da in der verwendeten CNN Simulationssoftware (siehe auch Abschnitt 4.2) mit entsprechender Präzision gerechnet wurde. Die Koeffizienten (siehe auch Gleichung 3.7) sind dabei, wie in Tabelle B.1 schematisch dargestellt, angeordnet.

Feedforward	$b_{(i-1)(j-1),1}$	$b_{(i)(j-1),1}$	$b_{(i+1)(j-1),1}$
	$b_{(i-1)(j-1),2}$	$b_{(i)(j-1),2}$	$b_{(i+1)(j-1),2}$
	$b_{(i-1)(j-1),3}$	$b_{(i)(j-1),3}$	$b_{(i+1)(j-1),3}$
	$b_{(i-1)(j),1}$	$b_{(i)(j),1}$	$b_{(i+1)(j),1}$
	$b_{(i-1)(j),2}$	$b_{(i)(j),2}$	$b_{(i+1)(j),2}$
	$b_{(i-1)(j),3}$	$b_{(i)(j),3}$	$b_{(i+1)(j),3}$
	$b_{(i-1)(j+1),1}$	$b_{(i)(j+1),1}$	$b_{(i+1)(j+1),1}$
	$b_{(i-1)(j+1),2}$	$b_{(i)(j+1),2}$	$b_{(i+1)(j+1),2}$
	$b_{(i-1)(j+1),3}$	$b_{(i)(j+1),3}$	$b_{(i+1)(j+1),3}$
Feedback	$a_{(i-1)(j-1),1}$	$a_{(i)(j-1),1}$	$a_{(i+1)(j-1),1}$
	$a_{(i-1)(j-1),2}$	$a_{(i)(j-1),2}$	$a_{(i+1)(j-1),2}$
	$a_{(i-1)(j-1),3}$	$a_{(i)(j-1),3}$	$a_{(i+1)(j-1),3}$
	$a_{(i-1)(j),1}$	$a_{(i)(j),1}$	$a_{(i+1)(j),1}$
	$a_{(i-1)(j),2}$	$a_{(i)(j),2}$	$a_{(i+1)(j),2}$
	$a_{(i-1)(j),3}$	$a_{(i)(j),3}$	$a_{(i+1)(j),3}$
	$a_{(i-1)(j+1),1}$	$a_{(i)(j+1),1}$	$a_{(i+1)(j+1),1}$
	$a_{(i-1)(j+1),2}$	$a_{(i)(j+1),2}$	$a_{(i+1)(j+1),2}$
	$a_{(i-1)(j+1),3}$	$a_{(i)(j+1),3}$	$a_{(i+1)(j+1),3}$
Bias	s_{ij}		

Tabelle B.1: Schema der Anordnung der Koeffizienten.

Feedforward	-1,0827331543	0,289294451475	-1,58935141563
	1,39256489277	-0,948840737343	-0,731103777885
	0,56338763237	0,383796870708	-1,89674067497
	0,129697352648	-0,177435457706	-2,06986451149
	2,02210617065	-1,03729963303	1,53583943844
	-0,388122141361	1,22138297558	-0,551465690136
	-1,70440626144	2,60053014755	-0,0199234858155
	0,832557022572	-0,567809700966	1,22695755959
	0,396684467793	-0,931097507477	-2,18973183632
Feedback	-1,46961843967	1,54361414909	-2,14898824692
	2,03170681	-2,98981499672	0,413183271885
	-0,776743233204	-1,40903902054	0,822629570961
	-1,37916660309	-2,77502655983	-2,66438889503
	0,673316121101	-1,12682616711	1,89891171455
	0,166980087757	-3,06541180611	-0,9224807024
	-0,723620712757	-2,66459679604	-1,14139342308
	-1,72245514393	-1,31043839455	-0,987665951252
	-0,692101478577	-1,15345561504	0,346234083176
Bias	1,11162805557		

Tabelle B.2: Template des CNN zur Charakterisierung der Interaktionsstärke zwischen gekoppelten Rössleroszillatoren.

Feedforward	-1,97970366478	3,10278058052	-0,628531336784
	-0,395861655474	1,47924458981	0,407956808805
	0,546393632889	-0,704664647579	-0,509339630604
	0,585376501083	-1,67317676544	0,528832435608
	0,247152253985	2,82227182388	-2,1148545742
	0,941525578499	0,321575015783	0,252427130938
	0,2644918859	-1,22037684917	1,39823687077
	0,0851567611098	0,610929012299	-0,123925484717
	0,515160441399	-0,632944524288	-0,930319905281
Feedback	-1,16848194599	-0,538878262043	-0,1749317348
	-0,101625688374	-1,42000472546	0,158874541521
	2,43915557861	0,0332962535322	-0,679097235203
	0,642194926739	-2,01975536346	-0,990983366966
	-0,51406532526	-1,33855080605	-1,46448040009
	-1,09887170792	-0,681812703609	1,38531327248
	-1,88932406902	-0,120955504477	0,316519171
	-0,439852833748	-0,670498371124	0,873480558395
	0,891673982143	0,685263991356	-0,445305764675
Bias	1,08469176292		

Tabelle B.3: Template des CNN zur Charakterisierung der Interaktionsrichtung zwischen gekoppelten Rössleroszillatoren.

Feedforward	1,45097470284	-0,291266947985	0,690590143204
	1,18464326859	-0,73234629631	1,19297361374
	1,12901592255	-0,0555251836777	-0,446031033993
	0,364993572235	1,53170514107	1,90210926533
	-0,0292908139527	-0,587519288063	0,479653298855
	-0,267516165972	-0,81489366293	-0,419640779495
	-0,352839559317	-0,910954773426	-0,200366675854
	1,91940426826	1,49410939217	0,45965462923
	0,717652440071	-0,409231185913	1,10518312454
Feedback	0,621069073677	1,06540608406	1,06372666359
	0,657881498337	0,0713954418898	-0,920529007912
	0,867517471313	0,670930504799	1,05136466026
	0,961136460304	0,316057026386	0,0372276902199
	-1,26942658424	0,380076795816	-1,54277455807
	0,694233059883	1,2243771553	-2,02274703979
	1,30101001263	-0,366575598717	0,94715821743
	-1,29551553726	0,770411849022	-1,59647881985
	0,844103932381	-1,60560917854	0,382155179977
Bias	1,01486587524		

Tabelle B.4: Template des CNN zur Charakterisierung der Interaktionsstärke zwischen gekoppelten Rössler- und Lorenzoszillatoren.

Feedforward	0,841934919357	-7,34092330933	-0,788287758827
	-0,038428902626	-1,09678530693	2,25260925293
	0,0488774105906	-1,28436136246	-3,15482187271
	-1,06983983517	-1,14024496078	-2,73747491837
	4,08800649643	1,17153954506	-1,83512401581
	3,00527858734	0,700589418411	0,564192831516
	1,54250967503	-3,81021881104	-0,114469826221
	-0,600925087929	-0,460198819637	-1,09236323833
	0,209266364574	-0,440922617912	-1,24999260902
Feedback	4,95527982712	-0,299649447203	0,903170228004
	-4,30276107788	-1,33539164066	-1,07738471031
	-3,22483110428	-0,653945207596	7,59917926788
	2,46624612808	-3,37609267235	-0,234708279371
	-4,69945383072	-2,15661239624	-3,55318689346
	2,69067406654	0,666633486748	-1,60799574852
	0,931265175343	1,9879925251	3,52215242386
	-4,55721092224	0,652107000351	2,419911623
	-2,53465056419	0,0792074203491	1,7533967495
Bias	9,28833866119		

Tabelle B.5: Template des CNN zur Charakterisierung der Interaktionsrichtung zwischen gekoppelten Rössler- und Lorenzoszillatoren.

Feedforward	0,385733008385	0,725051045418	0,715084552765
	0,561692476273	-0,831503510475	0,885241985321
	-0,153339028358	0,42767894268	0,80050599575
	0,132704496384	0,738941550255	-0,728899478912
	0,743365049362	-0,766994476318	-0,221351981163
	0,0836770534515	0,474719524384	-0,631961464882
	-0,769172489643	0,238041520119	0,475497961044
	0,224957942963	0,370104551315	0,247207999229
	-0,683087468147	0,582954525948	-0,803910493851
Feedback	-0,049011528492	0,648847460747	0,576768994331
	0,64574098587	0,947301506996	0,394176006317
	0,119897007942	0,933534026146	0,698779940605
	-0,0645160079002	0,988739967346	0,625498533249
	-0,668949484825	0,762128472328	-0,827440023422
	0,120804548264	-0,233290016651	-0,668195962906
	0,341235995293	0,613307952881	-0,422429978848
	-0,474008023739	0,63137948513	-0,419566988945
	0,624742507935	0,249572515488	-0,741577982903
Bias	-0,964380025864		

Tabelle B.6: Template von CNN(s, Pat A, TL03-TL09).

Feedforward	-0,441307038069	0,341468781233	0,104937322438
	0,161209151149	0,468306481838	-0,113994933665
	0,465180873871	-0,0719894468784	0,800844073296
	0,42468303442	-0,228729113936	-0,154120907187
	0,381612360477	0,113178834319	0,453021019697
	0,240900143981	0,105438701808	-0,0492823272943
	-0,311047434807	0,18253827095	-0,241481155157
	-0,0742975398898	0,699174523354	-0,0790371447802
	0,177897036076	0,0150168640539	0,418772190809
Feedback	-0,196975693107	0,258665263653	-0,271514952183
	-0,160855099559	-0,101575635374	0,0362243205309
	0,291536808014	0,170824289322	-0,167127683759
	0,0476922094822	-0,318266779184	-0,418085426092
	-0,171927690506	0,297125756741	-0,0283965822309
	0,181372895837	0,0839736536145	0,210484266281
	-0,0954620540142	-0,420030772686	0,273327797651
	-0,214677169919	-0,434205263853	-0,291660964489
	0,183418214321	0,261534750462	0,529111146927
Bias	-0,279984116554		

Tabelle B.7: Template von CNN(s, Pat A, TL05-TL06).

Feedforward	-0,14470423758	-0,212938591838	0,509427070618
	0,103121265769	-0,343921512365	0,107884943485
	-0,545130431652	-0,414947926998	0,186860516667
	0,0226967930794	0,171881049871	-0,59211140871
	0,472683012486	0,118352673948	0,354012459517
	0,00995393842459	-0,336588650942	0,25350689888
	-0,123194873333	0,389662772417	-0,675158143044
	0,534267365932	0,104816854	0,18062877655
	-1,05691504478	0,560343503952	0,0465971976519
Feedback	0,363339424133	-0,449234932661	-0,264615118504
	0,0737243890762	-0,331493616104	-0,42893832922
	-0,837091684341	0,583089351654	0,436936318874
	-0,578922510147	-0,476699411869	-0,26789611578
	0,0576482713223	-0,560613334179	0,743052780628
	-0,140165925026	-0,229908168316	-0,228991508484
	1,42033672333	0,59219199419	0,252799630165
	-0,741566479206	-0,109148621559	-0,650092065334
	-0,236789792776	0,536865651608	0,562874019146
Bias	0,438391238451		

Tabelle B.8: Template von CNN(s, Pat A, TR02-TR07).

Feedforward	0,512915015221	0,791334807873	-1,01941907406
	0,574635267258	-0,0223591234535	-0,0438112802804
	-0,0642480254173	0,506728589535	-0,54335975647
	-0,332617580891	-0,100714869797	0,531222999096
	0,492730945349	-0,128559857607	-0,620273768902
	-0,696507751942	-0,193091765046	-0,108812876046
	0,0384330041707	0,296814501286	-0,0183731615543
	-0,268894195557	0,348788946867	0,145396307111
	-0,0774434134364	0,22408080101	0,287571966648
Feedback	0,996619284153	0,186673805118	0,154066219926
	-0,371328949928	0,708860397339	0,5492182374
	-0,295641452074	-0,13254493475	0,327247291803
	0,0278418865055	-0,668439269066	0,357133358717
	-0,762345790863	-0,625103414059	-0,121233701706
	-0,227170988917	-0,118292987347	0,730662405491
	0,251874774694	0,646351575851	0,0333117097616
	0,42301183939	0,861844778061	0,591331124306
	-0,150380000472	-0,235617890954	0,235709622502
Bias	-0,980243742466		

Tabelle B.9: Template von CNN(s, Pat B, TR09-TL03).

Feedforward	-0,516391038895	0,121951133013	-2,77757000923
	1,35340440273	-0,993235766888	-0,372055232525
	0,853246212006	-0,336934089661	0,666093230247
	-0,579428970814	0,729793310165	1,60855770111
	-2,12981438637	0,554814815521	0,972927987576
	-0,210773348808	2,62017464638	-1,68230366707
	1,76001286507	-0,131393492222	-1,2248506546
	1,84822845459	2,80283284187	-0,365885436535
	-0,932999432087	-1,25902318954	0,807777881622
	0,647657036781	-0,449845016003	-0,40189525485
	0,833575189114	0,0216253697872	0,360103309155
	-0,797176063061	1,02247869968	0,435775995255
Feedback	0,0629721581936	0,490303426981	-0,33620429039
	-0,654258012772	-1,11552786827	-1,20620346069
	0,865266740322	0,441432327032	-0,350828528404
	0,601121485233	1,94866752625	0,625441610813
	0,313159495592	1,000192523	0,607818484306
	1,43106269836	-0,546075224876	-0,672888219357
Bias	-0,727180480957		

Tabelle B.10: Template von CNN(s, Pat B, TR10-TR06).

Feedforward	-0,392398327589	1,58740258217	-1,7127238512
	0,528570055962	-0,0940837115049	0,0744542479515
	1,44857656956	-0,382597148418	0,428452670574
	-0,426025241613	1,50846457481	-0,858342111111
	1,34521186352	-0,193377509713	-0,305519551039
	-1,02614939213	0,80390381813	0,215972647071
	-1,3586704731	0,667144238949	0,490862458944
	0,904596805573	1,81878709793	-0,315538644791
	-0,777833044529	0,381553560495	0,20802795887
	-1,25330424309	0,624979317188	-0,315925002098
	-1,05344569683	-0,0931521579623	0,798222005367
	-0,0649346932769	-0,543724417686	-0,144173830748
Feedback	1,33663868904	0,525084733963	-0,0900458469987
	-0,523384392262	0,00846062228084	0,241883590817
	0,630589187145	-0,0285741090775	0,638792455196
	0,340472340584	1,01082420349	-0,257246792316
	0,878216385841	0,00980738271028	0,697232306004
	1,18917226791	0,135431230068	0,379363179207
Bias	-1,06307268143		

Tabelle B.11: Template von CNN(s, Pat B, TL05-TL09).

Feedforward	-0,782445192337	-2,35583591461	-0,325857669115
	-0,0907780081034	3,00978159904	0,479218065739
	-1,0248862505	2,06571722031	-1,3587501049
	-1,63832259178	0,661283195019	-1,45025742054
	-1,59177780151	-0,29626840353	0,0369473695755
	-1,14247226715	-1,07557296753	2,56185436249
	-0,491435945034	1,9548112154	-0,379401087761
	1,67895340919	3,69025850296	1,80098855495
	0,484558284283	1,84228777885	-0,208666682243
	2,82458400726	1,60569787025	0,406702935696
	-2,06165266037	0,516819536686	2,78924107552
	1,5047249794	3,33499717712	1,12536895275
Feedback	1,65920126438	-1,00823736191	0,226458013058
	-0,332510590553	0,264524459839	-0,0108339376748
	0,841682136059	-1,06904625893	0,847975373268
	-1,56166744232	-0,500303506851	-0,901338994503
	1,29988777637	-2,10737395287	-1,18893039227
	1,51085412502	-3,39064359665	0,542131662369
Bias	0,0133619904518		

Tabelle B.12: Template von CNN(s, Pat C, TL03-TR10).

Feedforward	-0,157626748085	0,70490694046	0,519826173782
	-0,200356990099	0,575867593288	0,698925852776
	-0,31763112545	0,395218253136	-0,279434144497
	-0,749717235565	-0,154980391264	-0,686328053474
	0,700499355793	0,547544240952	0,796538889408
	1,29879784584	-0,113886058331	0,219137236476
	-0,783055484295	0,801411867142	0,422891378403
	0,591997206211	1,53299915791	0,725602388382
	-0,358550012112	-0,0724607259035	-0,532910704613
	0,538217246532	-0,61612868309	0,385984539986
	-1,57274794579	-0,366259366274	-0,282777220011
	0,533607244492	1,76714658737	0,677752077579
Feedback	1,15621328354	0,53814381361	0,922440111637
	0,703132152557	0,442656636238	0,148610904813
	0,00336247682571	0,783788025379	0,376735150814
	0,468922376633	-0,729804158211	-0,0712941884995
	0,160325706005	0,832285940647	-0,199202686548
	-0,0241006314754	-1,02061378956	0,0553226694465
Bias	-0,139609605074		

Tabelle B.13: Template von CNN(s, Pat C, TL07-TR08).

Feedforward	-2,35595846176	0,969419419765	-1,44194436073
	-0,366903603077	-0,226612985134	-1,32649469376
	0,666905522346	1,16699898243	-0,684949278831
	-0,405147135258	-0,859494566917	-0,547239542007
	0,0159954726696	0,67032623291	0,0899153053761
	1,83663356304	1,01946914196	0,373389333487
	0,136180639267	1,31298196316	1,25750911236
	0,519665896893	0,335011482239	-1,44657993317
	1,64491915703	-1,15396296978	0,146040201187
	-1,07944989204	-0,68620634079	0,88256508112
	0,634761929512	0,0832609385252	-0,599414527416
	-0,0359584093094	-0,472944825888	-1,11499798298
Feedback	1,225679636	-0,162416875362	0,395970374346
	1,12069642544	0,725312590599	-0,972252488136
	0,724014759064	0,342379748821	1,07370591164
	1,54806852341	0,987396121025	1,55003321171
	1,11238288879	-1,23797559738	0,837842643261
	0,657494664192	-0,611545085907	1,03059005737
Bias	-0,928073406219		

Tabelle B.14: Template von CNN(s, Pat C, TR02-TR03).

Feedforward	0,000795781612396	0,367965131998	0,187158793211
	0,35201883316	-1,26364946365	0,997224330902
	1,26507222652	-0,593603730202	-0,604355275631
	0,917438566685	-0,499640583992	-0,816129028797
	0,748132944107	0,226027101278	0,402269363403
	-0,795793831348	0,85932123661	-1,28474974632
	0,480298638344	-0,0397964417934	0,523166179657
	-0,3978099823	0,429065257311	0,46788713336
	-1,17546057701	-1,14215540886	0,769239187241
	1,2813013792	1,62345230579	1,39334702492
	-0,327960073948	0,2250341326	-0,501368403435
	0,835046052933	0,799218118191	-0,815832614899
Feedback	-0,420989513397	-2,09787082672	0,746651291847
	0,0682013034821	1,60928416252	0,931393146515
	0,729038536549	0,318908184767	-0,000309109687805
	-1,23173296452	-0,542133927345	0,159647598863
	0,341235339642	-0,0913545191288	0,428711056709
	-0,00381281971931	0,0946773737669	0,086483746767
Bias	-1,8385219574		

Tabelle B.15: Template von CNN(s, Pat A, M).

Feedforward	-0,34819740057	1,34489154816	-0,624030172825
	0,429962098598	-0,216722533107	0,254131942987
	-1,04124999046	0,224935173988	0,298567920923
	-0,081931643188	-1,22079324722	-0,0152708292007
	-0,314571678638	1,48535263538	0,117587149143
	0,152706876397	0,701190471649	1,52525496483
	0,29671806097	-0,455195337534	1,16071712971
	-0,326575219631	1,10744440556	-1,773660779
	-0,217530801892	-0,0394069366157	0,0236023571342
Feedback	0,698519349098	-0,25473049283	0,952719211578
	1,83754122257	-0,20828409493	1,50275111198
	0,387786507607	0,507126152515	-1,19560742378
	-0,413401395082	-0,589442312717	-0,763977825642
	-1,35532045364	-1,8236874342	1,13485765457
	1,15177428722	-0,145724222064	0,431986600161
	0,670295000076	1,49768316746	-0,0546317659318
	-0,360697537661	-0,164305344224	0,321940600872
	0,254929035902	1,09560894966	-0,715064167976
Bias	-1,12901008129		

Tabelle B.16: Template von CNN(s, Pat B, M).

Feedforward	-0,466675102711	0,637028455734	-0,206923618913
	0,406209945679	0,948116064072	0,208620160818
	-1,2442060709	0,596803545952	0,41620823741
	-1,2365347147	-0,53502035141	0,939226448536
	1,98465764523	-0,307559460402	-1,06134366989
	-1,49483835697	0,930737435818	0,97305482626
	-0,66515648365	-0,910243749619	-0,24328994751
	0,200160622597	1,48810553551	0,816095113754
	-1,00481200218	-0,11156424135	0,35961163044
Feedback	0,706153512001	0,21220420301	-0,302771687508
	-0,767098605633	-0,704764604568	0,767713069916
	-0,283154696226	-0,56633991003	-0,241704449058
	0,950464129448	-0,297224789858	-0,327233433723
	-0,322766005993	-0,490584731102	-0,322425544262
	-0,700917959213	-1,22771060467	-0,129054635763
	-0,559781730175	0,310744315386	0,793954253197
	-0,992799043655	-1,37225389481	0,114922128618
	0,279118657112	0,556242406368	0,255081385374
Bias	1,05173039436		

Tabelle B.17: Template von CNN(s, Pat C, M).

Feedforward	0,465247601271	-0,687838494778	-0,705603301525
	0,13454566896	-0,460794657469	0,70647495985
	-0,173974469304	0,299454391003	0,270386576653
	-0,800175607204	0,761016190052	-0,182124719024
	1,50514149666	0,345694005489	0,437755167484
	-0,530416071415	-0,630175828934	0,730811655521
	0,491304278374	-1,04414772987	0,0238967183977
	1,47396397591	0,238362297416	-0,169570937753
	-0,53549861908	0,234236314893	1,31192088127
	0,575153470039	0,298489004374	-0,397224515676
	-0,0746785327792	-0,0391039960086	0,0988480821252
	0,956370294094	0,304874956608	1,35418593884
Feedback	-0,713175177574	-1,03652000427	1,13396406174
	0,563750267029	-0,602943181992	0,293248832226
	0,374277293682	0,0380699336529	0,948126733303
	-0,433824062347	0,0808504000306	-1,3017513752
	-0,454999774694	-0,316354513168	-0,572750329971
	-0,492208659649	-0,412270069122	0,792683720589
Bias	-0,0277481880039		

Tabelle B.18: Template von CNN(s, M, M).

Feedforward	0,80124771595	-0,218955293298	-0,275525391102
	-0,502887368202	-0,391063272953	-0,304941654205
	0,0325441807508	0,0918934345245	0,0992525666952
	-1,4767690897	1,22860896587	-0,0617217607796
	-0,186121314764	-0,39195266366	0,135435178876
	0,455427110195	0,6238925457	-0,269417047501
	-0,201936155558	-0,558390200138	-0,0745257362723
	0,00726708257571	-0,457556813955	-1,02055454254
	0,537865281105	0,589963138103	0,366150468588
	0,643019735813	0,457013130188	-0,456954956055
	0,503879845142	0,226129278541	0,173860251904
	0,838757097721	-0,0858827903867	0,976867496967
Feedback	0,065756842494	0,0839299485087	0,191062986851
	-0,420027703047	0,182893380523	1,22617268562
	-0,168233275414	-1,18176245689	0,488965213299
	-0,672113239765	-0,226194649935	-0,105336509645
	0,190340325236	0,739639341831	-0,0387436784804
	0,767046749592	-0,564624965191	-0,636980235577
Bias	-0,693496465683		

Tabelle B.19: Template von CNN(a, Pat A, TL01-TL06).

Feedforward	0,159866541624	-0,844842553139	1,346170187
	-0,821829736233	0,163001149893	-0,668687820435
	-0,273996949196	-0,535192251205	0,487912267447
	-0,930751979351	-0,1364903301	-0,308253735304
	-0,53539454937	0,233339250088	-1,12000787258
	-0,094067774713	0,98989790678	0,639759004116
	-0,171660929918	-0,782162189484	0,0588225722313
	-0,322797268629	-0,44496807456	0,497019380331
	0,475635260344	0,678859651089	-0,029258986935
Feedback	-0,437891095877	0,271564602852	-1,22113704681
	-0,788744390011	0,369514107704	-0,138780012727
	0,746029496193	0,519461810589	0,0307459831238
	-0,133990243077	-0,950742065907	0,11332397908
	1,15644562244	0,369934856892	-0,71627509594
	0,741945445538	0,779371380806	-0,0317223779857
	0,812392711639	0,400682449341	-0,0493727140129
	0,330267041922	1,12947666645	0,514652013779
	0,349619537592	-0,431517452002	0,101820908487
Bias	-0,739657878876		

Tabelle B.20: Template von CNN(a, Pat A, TL07-TR05).

Feedforward	0,461787879467	-0,53848284483	-0,681966125965
	-0,867742955685	-1,52514147758	-1,09749913216
	0,437183529139	-0,260490983725	0,462762147188
	0,546735644341	1,05198216438	0,626445651054
	-0,279370427132	0,590551316738	-0,227608159184
	0,793266355991	-1,11435008049	-0,472796469927
	0,299004524946	0,838525950909	-1,31572210789
	-0,450539261103	-0,225459426641	-0,232424736023
	-0,54962426424	-0,0220986697823	-1,04517066479
Feedback	0,189337179065	0,703752696514	0,888000607491
	-0,642622888088	0,0515273846686	-0,0624248497188
	0,282714784145	0,489814162254	1,03796780109
	0,83017539978	1,59965479374	-0,779360294342
	0,641935169697	0,686951637268	-0,110752396286
	-0,991601288319	-0,825069963932	0,774230718613
	-0,706951260567	-0,564317941666	0,735842168331
	-0,258133113384	-0,165583610535	0,952109098434
	-0,873220443726	0,0606242120266	-0,360474824905
Bias	-0,140489771962		

Tabelle B.21: Template von CNN(a, Pat A, TR03-TR08).

Feedforward	-0,209930479527	0,406211018562	-0,629368543625
	-0,0182719826698	0,932914972305	-0,0142740011215
	0,527369976044	-0,656490504742	-0,658133983612
	-0,593273997307	-0,971451997757	-0,590458989143
	0,20060801506	0,948189973831	-0,452356517315
	0,971048951149	-0,0118954777718	0,702619552612
	0,464027047157	-0,16268402338	-0,382094979286
	-0,938198983669	0,88595700264	-0,298748493195
	-0,0451055169106	0,1480884552	-0,314094483852
Feedback	0,672884941101	0,997872948647	0,174649953842
	-0,154478490353	-0,648959040642	0,132446050644
	0,0978399515152	0,368438959122	0,761057972908
	-0,249987483025	-0,691303014755	0,884850502014
	0,0146424770355	-0,276327490807	0,333174467087
	-0,883801519871	0,993093967438	0,848489046097
	-0,466662526131	-0,00868797302246	0,602379441261
	0,540770530701	0,282614469528	0,700523495674
	0,952490448952	-0,570150971413	-0,805242478848
Bias	-0,777045965195		

Tabelle B.22: Template von CNN(a, Pat B, TL03-TL10).

Feedforward	0,257640004158	0,00524735450745	-0,748617231846
	-1,37863409519	-0,861006379128	-0,652613520622
	0,0777176842093	1,82786941528	-1,45852005482
	-0,447483003139	0,832392036915	-0,950777053833
	-0,72594422102	0,0300286412239	-0,819414794445
	0,493839085102	0,0930349230766	-0,820415139198
	-0,615176558495	1,5337998867	-0,269432276487
	-1,13170588017	-1,68495965004	1,64875841141
	1,44148135185	-1,53487920761	-1,43244457245
Feedback	0,957362115383	-0,211919397116	1,05443370342
	-0,59073060751	-1,56770563126	1,63155329227
	0,996810972691	1,87891614437	0,469433754683
	-0,14478212595	0,292993873358	1,04992341995
	-0,134355694056	1,2448772192	1,24058890343
	-0,548152565956	-2,12529397011	-0,10011228919
	-0,0993606448174	0,244950920343	0,766762852669
	-0,261863857508	-0,637114822865	0,0673194602132
	-1,76349210739	0,418900340796	-0,70477771759
Bias	-0,162865325809		

Tabelle B.23: Template von CNN(a, Pat B, TL09-TR04).

Feedforward	0,893922805786	-0,756356716156	-1,01198339462
	-1,47599542141	-0,433818250895	-1,71098160744
	0,0532364249229	0,816874802113	0,00631851935759
	2,01497864723	-0,87461745739	-1,00622344017
	-0,984853982925	-2,14469075203	-0,997901201248
	-0,573010742664	-2,02112984657	2,30389547348
	0,237822830677	1,27899932861	-0,720448672771
	-1,31506371498	0,786139905453	-0,164345666766
	1,48335194588	1,4465585947	0,301529377699
Feedback	-2,02087688446	0,901072025299	-0,846601307392
	-1,03106880188	0,0161405839026	-0,79774415493
	0,184841036797	-1,60356545448	-1,57419776917
	2,16570329666	-2,10203695297	0,396856606007
	1,26485955715	0,570713162422	-0,914374709129
	-0,0107187731192	-0,451823800802	-0,637553691864
	0,620697677135	2,58872866631	0,986300945282
	0,676577210426	0,338904052973	-0,0297994222492
	2,66866850853	1,15725076199	2,42745614052
Bias	1,06633388996		

Tabelle B.24: Template von CNN(a, Pat B, TR04-TR08).

Feedforward	0,559925854206	-0,324646651745	-0,357656270266
	-0,699306249619	-0,0716776400805	-0,489354908466
	-0,132890343666	0,695677042007	-0,400143921375
	0,685335636139	-0,190404355526	0,167875468731
	-0,701724469662	-0,415670573711	-0,628240406513
	0,383786350489	0,951760053635	-0,253197401762
	-0,748065531254	-0,201041147113	0,275208175182
	-0,0783497691154	0,00334686785936	-0,986331105232
	0,130894809961	-0,0408623814583	0,161248892546
Feedback	-0,159652769566	0,509726405144	0,190472885966
	0,156843796372	-0,345039844513	0,0205363482237
	-0,527963280678	0,736116826534	0,197323620319
	-0,476485192776	-0,401270866394	0,244894430041
	0,328570604324	0,335669577122	0,682866930962
	0,366310060024	-0,310205429792	-0,58476793766
	0,683822631836	0,470994949341	0,252802699804
	0,25719755888	-0,641302227974	0,0907457172871
	0,136408627033	0,354017674923	0,529854536057
Bias	-0,0629993975163		

Tabelle B.25: Template von CNN(a, Pat A, M).

Feedforward	0,680900335312	0,931993961334	1,67562127113
	-1,04753148556	-1,04289317131	-1,40604448318
	-0,285833656788	1,48825192451	-3,4039683342
	-0,530582666397	-0,602920293808	-0,885676383972
	-0,0541116297245	1,68687617779	-3,65170049667
	0,152692198753	1,62914812565	0,4482601583
	-0,487433969975	1,14270496368	-0,776156425476
	-1,02232170105	-3,0788435936	1,25778734684
	-1,79695510864	-2,43123841286	-0,127772331238
	-0,878912866116	0,780085980892	-0,906089663506
	0,823391318321	-0,150344341993	1,31416463852
	-0,51894724369	9,99271869659e-05	-0,10637062788
Feedback	-0,601600706577	-2,21574163437	3,71030592918
	-3,30516433716	-2,21126794815	0,825267672539
	-2,77475690842	-2,32045340538	1,2136759758
	0,87664437294	-0,725722014904	2,00292944908
	2,65288686752	1,51838421822	-0,245868086815
	1,36511802673	1,12465047836	2,86472630501
Bias	-0,138606667519		

Tabelle B.26: Template von CNN(a, Pat B, M).

Feedforward	-0,509425580502	0,163401901722	-0,0142741175368
	0,249684393406	-0,574724197388	-0,783608019352
	-0,140451058745	-0,266458690166	0,435086846352
	-0,729148447514	0,568081140518	-0,243258565664
	-0,402217119932	-0,952892005444	-0,243802413344
	0,176267981529	0,0106439990923	-0,116870649159
	-0,00703919865191	-0,0725343450904	0,459046244621
	-0,448404461145	-0,733303964138	-1,87022745609
	0,293710142374	0,0397991500795	1,3018450737
	-0,206366986036	-0,0145547101274	0,772149205208
	0,571170032024	1,00106847286	0,827117502689
	0,433325886726	0,895826935768	-0,650113224983
Feedback	1,17058038712	-1,17631554604	-0,119816064835
	0,702026903629	-0,0996268242598	0,295927047729
	-1,06717705727	0,112417973578	0,839109301567
	0,503992974758	0,238673746586	0,342071771622
	-0,114855453372	-0,0738026946783	-0,732758998871
	-0,0655849725008	-1,16790890694	-0,047031968832
Bias	-0,239280939102		

Tabelle B.27: Template von CNN(a, M, M).

Literaturverzeichnis

- [AAGM01] E. Allaria, F. T. Arecchi, A. Di Garbo und R. Meucci. Synchronization of homoclinic chaos. *Phys. Rev. Lett.*, 86:791–794, 2001.
- [ABST93] H. D. I. Abarbanel, R. Brown, J. J. Sidorowich und L. Sh. Tsimring. The analysis of observed chaotic data in physical systems. *Rev. Mod. Phys.*, 65:1331, 1993.
- [ACEM09] R. G. Andrzejak, D. Chicharro, C. E. Elger und F. Mormann. Seizure prediction: Any better than chance? *Clin. Neurophysiol.*, 120:1465–1478, 2009.
- [ADL⁺02] M. Avoli, M. D’Antuono, J. Louvel, R. Köhling, G. Biagini, R. Pumain, G. D’Arcangelo und V. Tancredi. Network and pharmacological mechanisms leading to epileptiform synchronization in the limbic system in vitro. *Prog. Neurobiol.*, 68:167–207, 2002.
- [AEK90] D. G. Aronson, G. B. Ermentrout und N. Koppel. Amplitude response of coupled oscillators. *Physica D*, 41:403–449, 1990.
- [AG85] D. J. Amit und H. Gutfreund. Spin-glass models of neural networks. *Phys. Rev. A*, 32:1007–1018, 1985.
- [AGLE99] J. Arnhold, P. Grassberger, K. Lehnertz und C. E. Elger. A robust method for detecting interdependences: application to intracranially recorded EEG. *Physica D*, 134:419–430, 1999.
- [AHM⁺05] G. Alvarez, L. Hernandez, J. Munoz, F. Montoya und S. J. Li. Security analysis of communication system based on the synchronization of different order chaotic systems. *Phys. Lett. A*, 345:245–250, 2005.
- [AKS⁺03] R. G. Andrzejak, A. Kraskov, H. Stögbauer, F. Mormann und T. Kreuz. Bivariate surrogate techniques: Necessity, strengths, and caveats. *Phys. Rev. E*, 68:066202, 2003.

- [Ame98] C. Ames. Klassifikation von Neurosignalen mit künstlichen Zellularen Neuronalen Netzwerken. Diplomarbeit, Institut für angewandte Physik, Johann Wolfgang Goethe-Universität Frankfurt am Main, 1998.
- [AMK⁺03] R. G. Andrzejak, F. Mormann, T. Kreuz, C. Rieke, A. Kraskov, C. E. Elger und K. Lehnertz. Testing the null hypothesis of the nonexistence of a pre seizure state. *Phys. Rev. E*, 67:010901(R), 2003.
- [AMPR04] G. Alvarez, F. Montoya, G. Pastor und M. Romera. Breaking a secure communication scheme based on the phase synchronization of chaotic systems. *Chaos*, 14:274–278, 2004.
- [AP09] A. Ahlborn und U. Parlitz. Experimental observation of chaotic phase synchronization of a periodically modulated frequency-doubled Nd:YAG laser. *Opt. Lett.*, 34:2754–2756, 2009.
- [APHF92] A. M. Albano, A. Passamante, T. Heidiger und M. E. Farrell. Using neural nets to look for chaos. *Physica D*, 58:1–9, 1992.
- [ARS96] H. D. I. Abarbanel, N. Rulkov und M. Sushchik. Generalized synchronization of chaos: The auxiliary system approach. *Phys. Rev. E*, 53:4528–4535, 1996.
- [AVR86] V. S. Afraimovich, N. N. Verichev und M. I. Rabinovich. General synchronization. *Radiophys. Quantum Electron.*, 29:795–803, 1986.
- [BCW08] F. Bartolomei, P. Chauvel und F. Wendling. Epileptogenicity of brain structures in human temporal lobe epilepsy: a quantified study from intracerebral EEG. *Brain*, 131:1818–1830, 2008.
- [Ber29] H. Berger. Über das Elektroenkephalogramm des Menschen. *Arch. Psychiat. Nervenkrankh.*, 87:527–570, 1929.
- [BGQ⁺95] S. Blanco, H. Garcia, R. Quian Quiroga, L. Romanelli und O. A. Rosso. Stationarity of the EEG series. *IEEE Eng. Med. Biol.*, 4:395–399, 1995.
- [BJHH09] E. Beninca, K. D. Johnk, R. Heerkloss und J. Huisman. Coupled predator-prey oscillations in a chaotic food web. *Ecol. Lett.*, 12:1367–1378, 2009.

- [BK00] R. Brown und L. Kocarev. A unifying definition of synchronization for dynamical systems. *Chaos*, 10:344–349, 2000.
- [BKO⁺02] S. Boccaletti, J. Kurths, G. Osipov, D. L. Valladares und C. S. Zhou. The synchronization of chaotic systems. *Phys. Rep.*, 366:1–101, 2002.
- [BPP01] S. Boccaletti, L. M. Pecora und A. Pelaez. Unifying framework for synchronization of coupled dynamical systems. *Phys. Rev. E*, 63(6):066219, 2001.
- [BSG⁺00] R. Bakker, J. C. Schouten, C. L. Giles, F. Takens und C. M. van den Bleek. Learning chaotic attractors by neural networks. *Neural Comput.*, 12:2355–2383, 2000.
- [BT02a] M. Breakspear und J. R. Terry. Detection and description of nonlinear interdependence in normal multichannel human EEG data. *Clin. Neurophysiol.*, 113:735–753, 2002.
- [BT02b] M. Breakspear und J. R. Terry. Topographic organization of nonlinear interdependence in multichannel human EEG. *NeuroImage*, 16:822–835, 2002.
- [BTF⁺03] M. Breakspear, J. R. Terry, K. J. Friston, A. W. F. Harris, L.M. Williams, K. Brown, J. Brennan und E. Gordona. A disturbance of nonlinear interdependence in scalp EEG of subjects with first episode schizophrenia. *NeuroImage*, 20:466–478, 2003.
- [Buz06] G. Buzsáki. *Rhythms of the brain*. Oxford University Press, USA, 2006.
- [BWB⁺01] F. Bartolomei, F. Wendling, J. J. Bellanger, J. Règis und P. Chauvel. Neural networks involving the medial temporal structures in temporal lobe epilepsy. *Clin. Neurophysiol.*, 112:1746–1760, 2001.
- [BWE00] A. Bragin, C. L. Wilson und J. Engel Jr. Chronic epileptogenesis requires development of a network of pathologically interconnected neuron clusters: a hypothesis. *Epilepsia*, 41(Suppl.6):S144–S152, 2000.
- [BZM⁺98] E. H. Bertram, D. X. Zhang, P. Mangan, N. Fountain und D. Rempe. Functional anatomy of limbic epilepsy: a proposal for central synchronization of a diffusely hyperexcitable network. *Epilepsy Res.*, 32:194–205, 1998.

- [CA09] D. Chicharro und R. G. Andrzejak. Reliable detection of directional couplings using rank statistics. *Phys. Rev. E*, 80:026217, 2009.
- [Cas91] M. Casdagli. Chaos and deterministic versus stochastic nonlinear modeling. *J. Roy. Stat. Soc. B*, 54:303–328, 1991.
- [CGC⁺05] M. Ciszak, J. M. Gutierrez, A. S. Cofino, C. Mirasso, R. Toral, L. Pesquera und S. Ortin. Approach to predictability via anticipated synchronization. *Phys. Rev. E*, 72:046218, 2005.
- [Chu98] L. O. Chua. *CNN: A paradigm for complexity*. Singapore: World Scientific, 1998.
- [CK04] S. H. Chun und S. H. Kim. Automated generation of new knowledge to support managerial decision-making: case study in forecasting a stock market. *Expert Syst.*, 21:192–207, 2004.
- [CL07] A. Chernihovskyi und K. Lehnertz. Measuring synchronization with nonlinear excitable media. *Int. J. Bifurcation Chaos Appl. Sci. Eng.*, 17:3425–3429, 2007.
- [CMM⁺05] A. Chernihovskyi, F. Mormann, M. Müller, C. E. Elger, G. Baier und K. Lehnertz. EEG analysis with nonlinear excitable media. *J. Clin. Neurophysiol.*, 22:314–329, 2005.
- [CP93] T. L. Carroll und L. M. Pecora. Cascading synchronized chaotic systems. *Physica D*, 67:126–140, 1993.
- [CRV93] L. O. Chua, T. Roska und P. L. Venetianer. The CNN is universal as the turing machine. *IEEE Trans. Circuits Syst.*, 40:289–291, 1993.
- [CY88a] L. O. Chua und L. Yang. Cellular neural networks: applications. *IEEE Trans. Circuits Syst.*, 35:1273–1290, 1988.
- [CY88b] L. O. Chua und L. Yang. Cellular neural networks: theory. *IEEE Trans. Circuits Syst.*, 35:1257–1272, 1988.
- [DBOR01] D. J. DeShazer, R. Breban, E. Ott und R. Roy. Detecting phase synchronization in a chaotic laser array. *Phys. Rev. Lett.*, 87:044101, 2001.
- [DBOR04] D. J. DeShazer, R. Breban, E. Ott und R. Roy. Phase synchronization

- in a modulated chaotic laser array. *Int. J. Bifurcation Chaos*, 14:3205–3216, 2004.
- [Dic10] H. Dickten. Approximation nichtlinearer Interdependenzmaße mit Zellularen Neuronalen Netzen - Einfluss der Netzwerktopologie. Diplomarbeit, Klinik für Epileptologie und Helmholtz-Institut für Strahlen- und Kernphysik, Universität Bonn, 2010.
- [DSSW06] J. S. Duncan, J. W. Sander, S. M. Sisodiya und M. C. Walker. Adult epilepsy. *Lancet*, 367:1087–1100, 2006.
- [Dun07] J. S. Duncan. Epilepsy surgery. *Clin. Med.*, 7:137–142, 2007.
- [EKKK95] E. Eisenstein, I. Kanter, D. A. Kessler und W. Kinzel. Generation and prediction of time series by a neural network. *Phys. Rev. Lett.*, 74:6–9, 1995.
- [Elg01] C. E. Elger. Future trends in epileptology. *Curr. Opin. Neurol.*, 14:185–186, 2001.
- [EP07] J. Jr. Engel und T. A. Pedley. *Epilepsy: A Comprehensive Textbook, 2nd ed.* Lippincott, Williams & Wilkins, Philadelphia, 2007.
- [ERRN06] M. Ercsey-Ravasz, T. Roska und Z. Neda. Stochastic simulations on the cellular wave computers. *Eur. Phys. J. B*, 51(3):407–411, 2006.
- [ERRN08] M. Ercsey-Ravasz, T. Roska und Z. Neda. Statistical physics on cellular neural network computers. *Physica D*, 237(9):1226–1234, 2008.
- [FKK02] A. Freking, W. Kinzel und I. Kanter. Learning and predicting time series by neural networks. *Phys. Rev. E*, 65:050903, 2002.
- [FNK03] H. Fukuda, H. Nagano und S. Kai. Stochastic synchronization in two-dimensional coupled lattice oscillators in the Belousov-Zhabotinsky reaction. *J. Phys. Soc. Jpn.*, 72(3):487–490, 2003.
- [FPN08] Luca Faes, Alberto Porta und Giandomenico Nollo. Mutual nonlinear prediction as a tool to evaluate coupling strength and directionality in bivariate time series: Comparison among different strategies based on k nearest neighbors. *Phys. Rev. E*, 78:026201, 2008.

- [FY83] H. Fujisaka und T. Yamada. Stability theory of synchronized motion in coupled dynamical systems. *Prog. Theor. Phys.*, 69:32–47, 1983.
- [Gal06] B. A. Galvan. Simulation of nonlinear excitable media with Cellular Nonlinear Networks. Diplomarbeit, Klinik für Epileptologie und Helmholtz-Institut für Strahlen- und Kernphysik, Universität Bonn, 2006.
- [GFC⁺92] J. F. Gibson, J. D. Farmer, M. Casdagli, und S. Eubank. An analytic approach to practical state space reconstruction. *Physica D*, 57:1–30, 1992.
- [Gla01] L. Glass. Synchronization and rhythmic processes in physiology. *Nature*, 410:277–284, 2001.
- [Glü09] D. Glüsenkamp. Messung direktonaler Abhängigkeiten in dynamischen Systemen mit Zellularen Nichtlinearen Netzen. Diplomarbeit, Klinik für Epileptologie und Helmholtz-Institut für Strahlen- und Kernphysik, Universität Bonn, 2009.
- [Got08] J. Gotman. Epileptic networks studied with EEG-fMRI. *Epilepsia*, 49 (Suppl. 3):42–51, 2008.
- [GP83] P. Grassberger und I. Procaccia. On the characterization of strange attractors. *Phys. Rev. Lett.*, 50:346, 1983.
- [GRG06] R. Gareta, L. M. Romeo und A. Gil. Forecasting of electricity prices with neural networks. *Energy Conv. Manag.*, 47:1770–1778, 2006.
- [GRT⁺06] M. Guye, J. Règis, M. Tamura, F. Wendling, A. McGonial, P. Chauvel und F. Bartolomei. The role of corticothalamic coupling in human temporal lobe epilepsy. *Brain*, 129:1917–1928, 2006.
- [Gue06] R. Guerrini. Epilepsy in children. *Lancet*, 367:499–524, 2006.
- [Han97] T. Hanne. Concepts of a learning object-oriented problem solver (LOOPS). In G. Fandel, T. Gal und T. Hanne (Hrsg.), *Proceedings of the 12th International Conference on Multiple criteria decision making*. Springer, Berlin, 1997.
- [HdW09] W. A. Hofsta und A. W. de Weerd. The circadian rhythm and its

- interaction with human epilepsy: a review of literature. *Sleep Medicine Reviews*, 13:413–420, 2009.
- [Heb49] D. O. Hebb. *The Organization of Behaviour*. Wiley, New York, 1949.
- [HK05] A. E. Hramov und A. A. Koronovskii. Generalized synchronization: A modified system approach. *Phys. Rev. E*, 71:067201, 2005.
- [Hop82] J.J. Hopfield. Neural networks and physical systems with emergent computational abilities. *Proc. Natl. Acad. Sci. USA*, 79:2554–2558, 1982.
- [Hop84] J.J. Hopfield. Neurons with graded response have computational properties like those of two-state neurons. *Proc. Natl. Acad. Sci. USA*, 81:3088–3092, 1984.
- [HSPVB07] K. Hlaváčková-Schindler, M. Paluš, M. Vejmelka und J. Bhattacharya. Causality detection based on information-theoretic approaches in time series analysis. *Phys. Rep.*, 441:1–46, 2007.
- [Huy73] C. (Hugenii) Huygens. *Horologium Oscillatorium*. Apud F. Muguet, Parisiis, 1673.
- [ISP⁺05] L.D. Iasemidis, D.-S. Shiau, P.M. Pardalos, W. Chaovalitwongse, K. Narayanan, A. Prasad, K. Tsakalis, P.R. Carney und J.C. Sackellares. Long-term prospective on-line real-time seizure prediction. *Clin. Neurophysiol.*, 116:532 – 544, 2005.
- [KAM⁺04] T. Kreuz, R. G. Andrzejak, F. Mormann, A. Kraskov, H. Stögbauer, C. E. Elger, K. Lehnertz und P. Grassberger. Measure profile surrogates: A method to validate the performance of epileptic seizure prediction algorithms. *Phys. Rev. E*, 69:061915, 2004.
- [KB06] P. Kwan und M. J. Brodie. Combination therapy in epilepsy – When and what to use. *Drugs*, 66:1817–1829, 2006.
- [KCO⁺06] D. Krug, A. Chernihovsky, H. Osterhage, C. E. Elger und K. Lehnertz. Estimating generalized synchronization in brain electrical activity from epilepsy patients with cellular nonlinear networks. In V. Tavasoglu und S. Arik (Hrsg.), *Proc. 10th IEEE International Workshop on Cellular Neural Networks and their Applications*, S. 68–72. IEEE-Press, 2006.

- [KES⁺04] M. A. Kramer, E. Edwards, M. Soltani, M. S. Berger, R. T. Knight und A. J. Szeri. Synchronization measures of bursting data: Application to the electrocorticogram of an auditory event-related experiment. *Phys. Rev. E*, 70:011914, 2004.
- [KLM⁺06] P. Kahane, E. Landré, L. Minotti, S. Francione und P. Ryvlin. The Bancaud and Talairach view on the epileptogenic zone: a working hypothesis. *Epileptic Disord.*, 8 (Suppl. 2):S16–S26, 2006.
- [KOEL07] D. Krug, H. Osterhage, C. E. Elger und K. Lehnertz. Estimating nonlinear interdependences in dynamical systems using cellular nonlinear networks. *Phys. Rev. E*, 76:041916, 2007.
- [Koh82] T. Kohonen. Self-organized formation of topologically correct feature maps. *Biol. Cybern.*, 43:59–69, 1982.
- [KPP97] D. R. Kulkarni, J. C. Parikh und R. Pratap. Simulation of characteristics and artificial neural network modeling of electroencephalograph time series. *Phys. Rev. E*, 55:4508–4511, 1997.
- [KR00] R. Kunz und R. Tetzlaff. Evolutionary learning strategies for cellular neural networks. In *Proceedings of the IEEE Int. Workshop on Cellular Neural Networks and Their Applications, Catania*, 2000.
- [Kra06] T. Kranz. Messung von Stabilitätseigenschaften dynamischer Systeme mit Zellularen Nichtlinearen Netzen. Diplomarbeit, Klinik für Epileptologie und Helmholtz-Institut für Strahlen- und Kernphysik, Universität Bonn, 2006.
- [Kru06] D. Krug. Approximation nichtlinearer Interdependenzmaße mit Zellularen Neuronalen Netzen. Diplomarbeit, Klinik für Epileptologie und Helmholtz-Institut für Strahlen- und Kernphysik, Universität Bonn, 2006.
- [KS03] H. Kantz und T. Schreiber. *Nonlinear Time Series Analysis, 2nd ed.* Cambridge Univ. Press, Cambridge, UK, 2003.
- [LAB⁺98] M. Le Van Quyen, C. Adam, M. Baulac, J. Martinerie und F. J. Varela. Nonlinear interdependencies of EEG signals in human intracranially recorded temporal lobe seizures. *Brain Res.*, 792:24, 1998.
- [LBH⁺09] K. Lehnertz, S. Bialonski, M.-T. Horstmann, D. Krug, A. Rothkegel,

- M. Staniek und T. Wagner. Synchronization phenomena in human epileptic brain networks. *J. Neurosci. Methods*, 183:42–48, 2009.
- [LC08] A. F. Luat und H. T. Chugani. Molecular and diffusion tensor imaging of epileptic networks. *Epilepsia*, 49 (Suppl. 3):15–22, 2008.
- [LGT⁺09] P. Van Leeuwen, D. Geue, M. Thiel, D. Cysarz, S. Lange, M. C. Romano, J. Kurths und D. H. Groenemeyer. Influence of paced maternal breathing on fetal-maternal heart rate coordination. *P. Natl. Acad. Sci. USA*, 106:13661–13666, 2009.
- [LLL07] K. Lehnertz, M. Le Van Quyen und B. Litt. Seizure prediction. In J. Engel Jr. und T. A. Pedley (Hrsg.), *Epilepsy: A Comprehensive Textbook, 2nd ed.*, S. 1011–1024. Lippincott, Williams & Wilkins, Philadelphia, 2007.
- [LMAV99] M. Le Van Quyen, J. Martinerie, C. Adam und F. J. Varela. Nonlinear analyses of interictal EEG map the brain interdependences in human focal epilepsy. *Physica D*, 127:250–266, 1999.
- [LMO⁺07] K. Lehnertz, F. Mormann, H. Osterhage, A. Müller, A. Chernihovskyi, M. Staniek, J. Prusseit, D. Krug, S. Bialonski und C. E. Elger. State-of-the-art of seizure prediction. *J. Clin. Neurophysiol.*, 24:147–153, 2007.
- [Lor63] E. N. Lorenz. Deterministic non-periodic flow. *J. Atmos. Sci.*, 20:130–141, 1963.
- [LPKH02] M. Laiho, A. Paasio, A. Kananen und K. Halonen. A mixed-mode polynomial-type CNN for analysing brain electrical activity in epilepsy. *Int. J. Circ. Theor. Appl.*, 30:165–180, 2002.
- [LPKH04] M. Laiho, A. Paasio, A. Kananen und K. Halonen. A mixed-mode polynomial cellular array processor hardware realization. *IEEE Trans. Circuits Syst.*, 51:286–297, 2004.
- [LSN⁺05] M. Le Van Quyen, J. Soss, V. Navarro, R. Robertson, M. Chavez, M. Baulac und J. Martinerie. Preictal state identification by synchronization changes in long-term intracranial EEG recordings. *Clin. Neurophysiol.*, 116:559–568, 2005.

- [LW08] R.P. Lesser und W.R.S. Webber. Seizure detection: Reaching through the looking glass. *Clin. Neurophysiol.*, 119:2667–2668, 2008.
- [MAK⁺03] F. Mormann, R. Andrzejak, T. Kreuz, C. Rieke, P. David, C. E. Elger und K. Lehnertz. Automated detection of a preseizure state based on a decrease in synchronization in intracranial electroencephalogram recordings from epilepsy patients. *Phys. Rev. E*, 67:021912, 2003.
- [MG09] S. Mukherjee und N. Gupte. Queue-length synchronization in communication networks. *Phys. Rev. E*, 79:056105, 2009.
- [MKA⁺03] F. Mormann, T. Kreuz, R. G. Andrzejak, P. David, K. Lehnertz und C. E. Elger. Epileptic seizures are preceded by a decrease in synchronization. *Epilepsy Res.*, 53:173–185, 2003.
- [MKR⁺05] F. Mormann, T. Kreuz, C. Rieke, R. G. Andrzejak, A. Kraskov, P. David, C. E. Elger und K. Lehnertz. On the predictability of epileptic seizures. *Clin. Neurophysiol.*, 116:569–587, 2005.
- [MLDE00] F. Mormann, K. Lehnertz, P. David und C. E. Elger. Mean phase coherence as a measure for phase synchronization and its application to the EEG of epilepsy patients. *Physica D*, 144:358–369, 2000.
- [Mor06] M. Morrell. Brain stimulation for epilepsy: can scheduled or responsive neurostimulation stop seizures? *Curr. Opin. Neurol.*, 19:164–168, 2006.
- [MP43] W. S. McCulloch und W. Pitts. A logical calculus of the ideas immanent in nervous activity. *Bull. Math. Biophys.*, 5:115–133, 1943.
- [MP69] M. Minsky und S. Papert. *Perceptrons: An Introduction to Computational Geometry*. MIT Press, Cambridge, MA, 1969.
- [NL05] E. Niedermeyer und F. Lopes da Silva. *Electroencephalography: Basic Principles, Clinical Applications, and Related Fields*. Lippincott Williams and Williams, Philadelphia, 2005.
- [NRT⁺10] Jakob Nawrath, M. Carmen Romano, Marco Thiel, István Z. Kiss, Mahesh Wickramasinghe, Jens Timmer, Jürgen Kurths und Björn Schelter. Distinguishing direct from indirect interactions in oscillatory networks with multiple time scales. *Phys. Rev. Lett.*, 104:038701, 2010.
- [NZN⁺08] G. Nolte, A. Ziehe, V. V. Nikulin, A. Schlögl, N. Krämer, T. Brismar

- und K.-R. Müller. Robustly estimating the flow direction of information in complex physical systems. *Phys. Rev. Lett.*, 100:234101, 2008.
- [OMWL07] H. Osterhage, F. Mormann, T. Wagner und K. Lehnertz. Measuring the directionality of coupling: phase versus state space dynamics and application to EEG time series. *Int. J. Neural. Syst.*, 17:139–148, 2007.
- [OMWL08] H. Osterhage, F. Mormann, T. Wagner und K. Lehnertz. Detecting directional coupling in the human epileptic brain: Limitations and potential pitfalls. *Phys. Rev. E*, 77:011914, 2008.
- [OS94] E. Ott und J. C. Sommerer. Blowout bifurcations: the occurrence of riddled basins and on-off intermittency. *Phys. Lett. A*, 188:39–47, 1994.
- [Ost08] H. Osterhage. Messungen der Stärke und Richtung von Interaktionen im epileptischen Gehirn des Menschen. Dissertation, Mathematisch-Naturwissenschaftliche Fakultät, Universität Bonn, 2008.
- [Pal96] M. Paluš. Nonlinearity in normal human EEG: Cycles, temporal asymmetry, nonstationarity and randomness, not chaos. *Biol. Cybern.*, 75:389–396, 1996.
- [Pal08] M. Paluš. Bootstrapping multifractals: Surrogate data from random cascades on wavelet dyadic trees. *Phys. Rev. Lett.*, 101:134101, 2008.
- [PC90] L. M. Pecora und T. L. Carroll. Synchronization in chaotic systems. *Phys. Rev. Lett.*, 64:821–824, 1990.
- [PCH95] L. M. Pecora, T. L. Carroll und J. F. Heagy. Statistics for mathematical properties of maps between time series embeddings. *Phys. Rev. E*, 52:3420–3439, 1995.
- [PCJ⁺97] L. M. Pecora, T. L. Carroll, G. A. Johnson, D. J. Mar und J. F. Heagy. Fundamentals of synchronization in chaotic systems, concepts and applications. *Chaos*, 7:520, 1997.
- [PK05] K.L. Priddy und P.E. Keller. *Artificial neural networks: an introduction*. SPIE Press, Bellingham, WA, 2005.
- [PL07] J. Prusseit und K. Lehnertz. Stochastic qualifiers of epileptic brain dynamics. *Phys. Rev. Lett.*, 98:138103, 2007.

- [PM08] A. A. Prokhorov und E. S. Mchedlova. Chaos synchronization with signal distortion in a communication channel: Experiment and numerical simulation. *Tech. Phys.*, 53:1463–1470, 2008.
- [PQB05] E. Pereda, R. Quian Quiroga und J. Bhattacharya. Nonlinear multivariate analysis of neurophysiological signals. *Prog. Neurobiol.*, 77:1–37, 2005.
- [PRGG01] E. Pereda, R. Rial, A. Gamundi und J. Gonzalez. Assessment of changing interdependencies between human electroencephalograms using non-linear methods. *Physica D*, 148:147–158, 2001.
- [PRK92] J. Principe, A. Rathie und J. Kuo. Prediction of chaotic time series with neural networks. *Int. J. Bifurcation Chaos Appl. Sci. Eng.*, 2:989, 1992.
- [PRK01] A. S. Pikovsky, M. G. Rosenblum und J. Kurths. *Synchronization: A universal concept in nonlinear sciences*. Cambridge University Press, Cambridge, UK, 2001.
- [PST93] N. Platt, A. Spiegel und C. Tresser. On-off intermittency: a mechanism for bursting. *Phys. Rev. Lett.*, 70:279–282, 1993.
- [PTPV06] N. G. Pavlidis, D. K. Tasoulis, V. P. Plagianakos und M. N. Vrahatis. Computational intelligence methods for financial time series modeling. *Int. J. Bifurcation Chaos Appl. Sci. Eng.*, 16:2053–2062, 2006.
- [PTVF02] W. H. Press, S. A. Teukolsky, W. T. Vetterling und B. P. Flannery. *Numerical Recipes in C*. Cambridge University Press, Cambridge, England, second. Aufl., 2002.
- [PV07] M. Paluš und M. Vejmelka. Directionality of coupling from bivariate time series: How to avoid false causalities and missed connections. *Phys. Rev. E*, 75:056211, 2007.
- [QAG00] R. Quian Quiroga, J. Arnhold und P. Grassberger. Learning driver-response relationships from synchronization patterns. *Phys. Rev. E*, 61:5142–5148, 2000.
- [QKKG02] R. Quian Quiroga, A. Kraskov, T. Kreuz und P. Grassberger. Performance of different synchronization measures in real data: A case study on electroencephalographic signals. *Phys. Rev. E*, 65:041903, 2002.

- [RALT09] T. Roska, P. Arena, C. T. Lin und R. Tetzlaff. Special issue on cellular wave computing architectures, part II. *Int. J. Circ. Theor. Appl.*, 37(4):503–504, 2009.
- [RAML04] C. Rieke, R. G. Andrzejak, F. Mormann und K. Lehnertz. Improved statistical test for nonstationarity using recurrence time statistics. *Phys. Rev. E*, 69:046111, 2004.
- [RD05] G. Roth und U. Dicke. Evolution of the brain and intelligence. *Trends Cogn. Sci.*, 9(5):250–257, 2005.
- [RL01] F. Rosenow und H. Lüders. Presurgical evaluation of epilepsy. *Brain*, 124:1683–1700, 2001.
- [RLC⁺04] A. Rodriguez-Vazquez, G. Linan-Cembrano, L. Carranza, E. Roca-Moreno, R. Carmona-Galan, F. Jimenez-Garrido, R. Dominguez-Castro und S. E. Meana. ACE16k: The third generation of mixed-signal SIMD-CNN ACE chips toward VSoCs. *IEEE Trans. Circuits Syst.*, 51:851–863, 2004.
- [RMA⁺03] C. Rieke, F. Mormann, R. G. Andrzejak, T. Kreuz, P. K. A. David, C. E. Elger und K. Lehnertz. Discerning nonstationarity from nonlinearity in seizure-free and pre-seizure EEG recordings from epilepsy patients. *IEEE Eng. Med. Biol.*, 50:634–639, 2003.
- [Ros58] F. Rosenblatt. The perceptron: A probabilistic model for information storage and organization in the brain. *Psychol. Rev.*, 65(6):386–408, 1958.
- [Rös76] O. E. Rössler. An equation for continuous chaos. *Phys. Lett. A*, 57:397–398, 1976.
- [Ros05] T. Roska. Cellular wave computers for brain-like spatial-temporal sensory computing. *IEEE Circ. Syst. Mag.*, 5:5–19, 2005.
- [Ros07] T. Roska. Cellular wave computers for nanotera-scale technology-beyond boolean, spatial-temporal logic in million processor devices. *Electron. Lett.*, 43:427–429, 2007.
- [Ros08] T. Roska. Cellular wave computer architectures in a new era of computing - 15 years later. *Int. J. Circ. Theor. Appl.*, 36(5-6):523–524, 2008.

- [RPK97] M. G. Rosenblum, A. S. Pikovsky und J. Kurths. From phase to lag synchronization in coupled chaotic oscillators. *Phys. Rev. Lett.*, 78:4193–4196, 1997.
- [RR02] T. Roska und A. Rodriguez-Vazquez. Toward visual microprocessors. *Proc. IEEE*, 90:1244–1257, 2002.
- [RRV00] T. Roska und A. Rodriguez-Vazquez. *Towards the visual microprocessor: VLSI Design and the use of Cellular Neural Network Universal Machines*. Chichester: J. Wiley, 2000.
- [RSA⁺02] C. Rieke, K. Sternickel, R. G. Andrzejak, C. E. Elger, P. David und K. Lehnertz. Measuring nonstationarity by analyzing the loss of recurrence in dynamical systems. *Phys. Rev. Lett.*, 88:244102, 2002.
- [RSTA95] N. F. Rulkov, M. M. Sushchik, L. S. Tsimring und H. D. I Abarbanel. Generalized synchronization of chaos in directionally coupled chaotic systems. *Phys. Rev. E*, 51:980–994, 1995.
- [RTK⁺09] M. C. Romano, M. Thiel, J. Kurths, K. Mergenthaler und R. Engbert. Hypothesis test for synchronization: Twin surrogates revisited. *Chaos*, 19:015108, 2009.
- [RTKG07] M.C. Romano, M. Thiel, J. Kurths und C. Grebogi. Estimation of the direction of the coupling by conditional probabilities of recurrence. *Phys. Rev. E*, 76:036211, 2007.
- [SCML05] R. Sowa, A. Chernihovskyi, F. Mormann und K. Lehnertz. Estimating phase synchronization in dynamical systems using cellular nonlinear networks. *Phys. Rev. E*, 71:061926, 2005.
- [SG05] A. Schnitzler und J. Gross. Normal and pathological oscillatory communication in the brain. *Nat. Rev. Neurosci.*, 6:285–296, 2005.
- [SL08a] W. C. Stacey und B. Litt. Technology insight: neuroengineering and epilepsy-designing devices for seizure control. *Nat. Clin. Pract. Neurol.*, 4:190–201, 2008.
- [SL08b] M. Staniek und K. Lehnertz. Symbolic transfer entropy. *Phys. Rev. Lett.*, 100:158101, 2008.
- [Sow04] R. Sowa. Untersuchung von Synchronisationsphänomenen in dyna-

- mischen Systemen mit Zellularen Neuronalen Netzen. Dissertation, Mathematisch-Naturwissenschaftliche Fakultät, Universität Bonn, 2004.
- [Spe02] S. S. Spencer. Neural networks in human epilepsy: Evidence of and implications for treatment. *Epilepsia*, 43:219–227, 2002.
- [SRKA98] C. Schäfer, M. G. Rosenblum, J. Kurths und H. H. Abel. Heartbeat synchronized with ventilation. *Nature*, 392:239–240, 1998.
- [SS00] T. Schreiber und A. Schmitz. Surrogate time series. *Physica D*, 142:346, 2000.
- [SSC⁺96] S. J. Schiff, P. So, T. Chang, R. E. Burke und T. Sauer. Detecting dynamical interdependence and generalized synchrony through mutual prediction in a neural ensemble. *Phys. Rev. E*, 54:6708–6724, 1996.
- [ST02] M. Small und C. K. Tse. Minimum description length neural networks for time series prediction. *Phys. Rev. E*, 66:066701, 2002.
- [SWM⁺06] B. Schelter, M. Winterhalder, T. Maiwald, A. Brandt, A. Schad, A. Schulze-Bonhage und J. Timmer. Testing statistical significance of multivariate time series analysis techniques for epileptic seizure prediction. *Chaos*, 16:013108, 2006.
- [SYC91] T. Sauer, J. Yorke und M. Casdagli. Embedology. *J. Stat. Phys.*, 65:579–616, 1991.
- [Tak81] F. Takens. Detecting strange attractors in turbulence. In D. A. Rand und L.-S. Young (Hrsg.), *Dynamical Systems and Turbulence (Warwick 1980)*, Band 898 aus der Reihe *Lecture Notes in Mathematics*, S. 366–381. Springer-Verlag, Berlin, 1981.
- [TF04] W. H. Theodore und R. S. Fisher. Brain stimulation for epilepsy. *Lancet Neurol.*, 3:111–118, 2004.
- [TGC09] A. Tar, G. Gandhi und G. Cserey. Hardware implementation of CNN architecture-based test bed for studying synchronization phenomenon in oscillatory and chaotic networks. *Int. J. Circ. Theor. Appl.*, 37:529–542, 2009.

- [The86] J. Theiler. Spurious dimensions from correlation algorithms applied to limited time-series data. *Phys. Rev. A*, 34:2427, 1986.
- [TKAW99] R. Tetzlaff, R. Kunz, C. Ames und D. Wolf. Analysis of brain electrical activity in epilepsy with cellular neural networks (CNN). In C. Beccari, M. Biey, P.P. Civalleri und M. Gilli (Hrsg.), *Proc. IEEE European Conference on Circuit Theory and Design*, S. 1007–1010, Turin, Italy, 1999. Levrotto & Bella.
- [TRK⁺06] M. Thiel, M. C. Romano, J. Kurths, M. Rolfs und R. Kliegl. Twin surrogates to test for complex synchronisation. *Europhys. Lett.*, 75:535–541, 2006.
- [UMP09] H. Ulrichs, A. Mann und U. Parlitz. Synchronization and chaotic dynamics of coupled mechanical metronomes. *Chaos*, 19:043120, 2009.
- [US06] P. J. Uhlhaas und W. Singer. Neural synchrony in brain disorders: relevance for cognitive dysfunctions and pathophysiology. *Neuron*, 52:155–168, 2006.
- [VKNS08] Z. Vörösházi, A. Kiss, Z. Nagy und P. Szolgay. Implementation of embedded emulated-digital CNN-UM global analogic programming unit on FPGA and its application. *Int. J. Circ. Theor. Appl.*, 36:589–603, 2008.
- [VLRM01] F. J. Varela, J. P. Lachaux, E. Rodriguez und J. Martinerie. The brain web: Phase synchronization and large-scale integration. *Nat. Rev. Neurosci.*, 2:229–239, 2001.
- [Wan07] L. Wang. Detection of complexity changes in dynamical systems with symbolic analysis and Cellular Neural Networks. Diplomarbeit, Klinik für Epileptologie und Helmholtz-Institut für Strahlen- und Kernphysik, Universität Bonn, 2007.
- [Whi36] H. Whitney. Differentiable manifolds. *Ann. Math.*, 37:645–680, 1936.
- [WRB93] T. L. H. Watkin, A. Rau und M. Biehl. The statistical mechanics of learning a rule. *Rev. Mod. Phys.*, 65:499–556, 1993.
- [ZRFS03] A. Zarandy, C. Rekeczky, P. Foldesy und I. Szatmari. The new framework of applications: The Aladdin system. *J. Circ. Syst. Comput.*, 12:769–781, 2003.

- [Zsc02] S. Zschocke. *Klinische Elektroenzephalographie*. Springer, Berlin, 2nd. Aufl., 2002.

Eigene Veröffentlichungen

Journalartikel

- [1] D. Krug, H. Osterhage, C. E. Elger und K. Lehnertz. Estimating nonlinear interdependences in dynamical systems using cellular nonlinear networks. *Phys. Rev. E*, 76:041916, 2007.
- [2] K. Lehnertz, S. Bialonski, M. T. Horstmann, D. Krug, A. Rothkegel, M. Staniek und T. Wagner. Synchronization phenomena in human epileptic brain networks. *J. Neurosci. Methods*, 183:42–48, 2009.
- [3] K. Lehnertz, F. Mormann, H. Osterhage, A. Müller, A. Chernihovskyi, M. Staniek, J. Prusseit, D. Krug, S. Bialonski und C. E. Elger. State-of-the-Art of Seizure Prediction. *J. Clin. Neurophysiol.*, 24:147–153, 2007.

Buchartikel

- [4] K. Lehnertz, S. Bialonski, M. T. Horstmann, D. Krug, A. Rothkegel, M. Staniek und T. Wagner. Epilepsy. In H. G. Schuster (Hrsg.), *Reviews of Nonlinear Dynamics and Complexity*, S. 159–200. Wiley-VCH, Berlin, 2009.
- [5] A. Chernihovskyi, D. Krug, C. E. Elger und K. Lehnertz. Time Series Analysis with Cellular Neural Networks. In B. Schelter, J. Timmer und A. Schulze-Bonhage (Hrsg.), *Seizure Prediction in Epilepsy: From Basic Mechanisms to Clinical Applications*, S. 131–148. Wiley-VCH, Weinheim, 2008.

Konferenzbeiträge (Proceedings)

- [6] D. Krug, C. E. Elger und K. Lehnertz. A CNN-based synchronization analysis for epileptic seizure prediction: Inter- and intraindividual generalization properties. In D. L. Vilariño, D. C. Ferrer und V. M. B. Sánchez (Hrsg.), *Proceedings of the 11th International Workshop on Cellular Neural Networks and their Applications*, S. 92–95. IEEE-Press, 2008.
- [7] D. Krug, A. Chernihovsky, H. Osterhage, C. E. Elger und K. Lehnertz. Estimating Generalized Synchronization in Brain Electrical Activity from Epilepsy Patients with Cellular Nonlinear Networks. In V. Tavsanoğlu und S. Arik (Hrsg.), *Proceedings of the 10th International Workshop on Cellular Neural Networks and their Applications*, S. 68–72. IEEE-Press, 2006.

Konferenzbeiträge (Abstracts)

- [8] D. Krug, C. E. Elger und K. Lehnertz. Detecting Preictal Synchronization Phenomena in the EEG with Cellular Neural Networks: Intra- and Interindividual Generalization Properties. *Epilepsia*, 49:17–17, 2008.
- [9] D. Krug, H. Osterhage, C. E. Elger und K. Lehnertz. Seizure Prediction: Measuring Generalized Synchronization and Directionality with Cellular Nonlinear Networks. *3rd International Workshop on Epileptic Seizure Prediction*, 2007.
- [10] D. Krug, H. Osterhage, C. E. Elger und K. Lehnertz. Seizure Prediction: Measuring the Degree of Generalized Synchronization in the EEG with Cellular Neural Networks. *Epilepsia*, 47:43–43, 2006.